

TUGAS AKHIR - KS 141501

**PERAMALAN JUMLAH WISATAWAN MANCANEGARA
YANG DATANG KE INDONESIA BERDASARKAN PINTU
MASUK MENGGUNAKAN METODE SUPPORT VECTOR
MACHINE (SVM)**

***FORECASTING NUMBER OF FOREIGN TOURISTS
ARRIVAL TO INDONESIA BASED ON ENTRANCE USING
SUPPORT VECTOR MACHINE (SVM) METHOD***

**MUHAMMAD FARHAN NAUFAL
NRP 5213 100 045**

**Dosen Pembimbing :
Wiwik Anggraeni, S.Si., M.Kom.**

**DEPARTEMEN SISTEM INFORMASI
Fakultas Teknologi Informasi
Institut Teknologi Sepuluh Nopember
Surabaya 2017**



ITS
Institut
Teknologi
Sepuluh Nopember

TUGAS AKHIR - KS 141501

**PERAMALAN JUMLAH WISATAWAN MANCANEGARA
YANG DATANG KE INDONESIA BERDASARKAN PINTU
MASUK MENGGUNAKAN METODE SUPPORT VECTOR
MACHINE (SVM)**

MUHAMMAD FARHAN NAUFAL
NRP 5213 100 045

Dosen Pembimbing :
Wiwik Anggraeni, S.Si., M.Kom.

DEPARTEMEN SISTEM INFORMASI
Fakultas Teknologi Informasi
Institut Teknologi Sepuluh Nopember
Surabaya 2017



FINAL PROJECT - KS 141501

***FORECASTING NUMBER OF FOREIGN TOURISTS
ARRIVAL TO INDONESIA BASED ON ENTRANCE USING
SUPPORT VECTOR MACHINE (SVM) METHOD***

**MUHAMMAD FARHAN NAUFAL
NRP 5213 100 045**

**Supervisor:
Wiwik Anggraeni, S.Si., M.Kom.**

**DEPARTEMEN SISTEM INFORMASI
Fakultas Teknologi Informasi
Institut Teknologi Sepuluh Nopember
Surabaya 2017**

LEMBAR PENGESAHAN

PERAMALAN JUMLAH WISATAWAN MANCANEGARA YANG DATANG KE INDONESIA BERDASARKAN PINTU MASUK MENGGUNAKAN METODE SUPPORT VECTOR MACHINE (SVM)

TUGAS AKHIR


Disusun untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Komputer
pada
Departemen Sistem Informasi
Fakultas Teknologi Informasi
Institut Teknologi Sepuluh Nopember

Oleh:

MUHAMMAD FARHAN NAUFAL
5213 100 045

Surabaya, Juli 2017

**KEPALA
DEPARTEMEN SISTEM INFORMASI**



Dr. Ir. Aris Triahyanto, M. Kom.
NIP 19650310 199102 1 001

LEMBAR PERSETUJUAN

PERAMALAN JUMLAH WISATAWAN MANCANEGARA YANG DATANG KE INDONESIA BERDASARKAN PINTU MASUK MENGGUNAKAN METODE SUPPORT VECTOR MACHINE (SVM)

TUGAS AKHIR

Disusun Untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Komputer
pada
Jurusan Sistem Informasi
Fakultas Teknologi Informasi
Institut Teknologi Sepuluh Nopember

Oleh :

MUHAMMAD FARHAN NAUFAL
NRP. 5213 100 045

Disetujui Tim Penguji : Tanggal Ujian : 14 Juni 2017
Periode Wisuda : September 2017

Wiwik Anggraeni, S.Si., M.Kom.

Edwin Riksakomara, S.Kom., M.T.

Ahmad Mukhlason, S.Kom, M.Sc, Ph.D.


(Pembimbing I)


(Penguji I)


(Penguji II)

PERAMALAN JUMLAH WISATAWAN MANCANEGERA YANG DATANG KE INDONESIA BERDASARKAN PINTU MASUK MENGGUNAKAN METODE SUPPORT VECTOR MACHINE (SVM)

Nama Mahasiswa : Muhammad Farhan Naufal
NRP : 5213 100 045
Departemen : Sistem Informasi FTIf-ITS
Pembimbing I : Wiwik Anggraeni, S.Si., M.Kom.

ABSTRAK

Pariwisata merupakan salah satu dari beberapa industri besar di dunia dan merupakan faktor penting dalam perkembangan ekonomi global . Perkembangan pariwisata semakin pesat dengan disertai kebutuhan manusia untuk berekreasi yang semakin meningkat. Berbagai sarana dan prasarana penunjang kegiatan pariwisata bermunculan, tumbuh dan berkembang dengan pesat. Pariwisata di Indonesia sendiri merupakan sektor ekonomi yang cukup penting dan menempati urutan ketiga dalam hal penerimaan devisa. Banyaknya potensi kekayaan alam dan budaya yang tersebar secara berlimpah menjadikan setiap daerah Indonesia memiliki objek wisata yang dapat menarik para wisatawan baik lokal maupun mancanegara.

Indonesia dikenal sebagai Negara yang memiliki kepulauan terbesar di dunia dengan beragam keindahan alam. Dengan begitu, Indonesia dapat dengan mudah menarik para wisatawan terutama bagi para wisatawan mancanegara yang ingin lebih mengenal Indonesia. Tetapi jumlah wisatawan dapat berubah sewaktu-waktu pada dampak yang dapat diakibatkan oleh suatu kondisi tertentu. Dan dalam upaya untuk meminimalisir jumlah wisatawan yang tidak tentu tersebut, maka dalam penelitian ini akan diramalkan jumlah wisatawan mancanegara yang datang ke Indonesia berdasarkan 6 pintu masuk dari 19 pintu masuk utama. Pada 19 pintu masuk hanya dipilih 6 dikarenakan untuk membatasi

penelitian. Dimana hasil peramalan dan prediksi yang akurat dari perkiraan jumlah wisatawan mancanegara di masa depan dapat memberikan strategi yang tepat bagi industri pariwisata.

Pada penelitian ini, digunakan metode SVM untuk meramalkan jumlah wisatawan mancanegara yang datang ke Indonesia dari 6 pintu masuk. Pintu masuk dipilih berdasarkan hasil klasterisasi K-means yang dibagi menjadi 3 klaster yakni tinggi, sedang dan rendah. Masing-masing klaster kemudian hanya dipilih dua sebagai contoh yang diambil dari nilai tertinggi dan terendah berdasarkan rata-rata jumlah wisman. Penggunaan SVM sendiri memiliki kelebihan yaitu dapat menangani permasalahan linier dan non-linier. Sehingga dapat dilakukan untuk melakukan peramalan data time series dengan berbagai macam pola yang ada. Selain itu, tidak hanya memprediksi permasalahan non-linier tetapi juga menawarkan akurasi yang cukup baik.

Hasil yang diperoleh dari uji coba penelitian ini menunjukkan bahwa model peramalan secara keseluruhan tergolong baik. Rata-rata akurasi dari 6 model memiliki MAPE sekitar 10% dengan nilai terkecil yakni 4.50% pada pintu masuk Ngurah Rai. Selain itu, hasil dari SVM juga memiliki akurasi perubahan arah data atau Directional Change Accuracy (DCA) yang cukup baik. Hal ini dibuktikan dengan hasil rata-rata DCA secara keseluruhan sebesar 62.64% dengan nilai tertinggi yakni 64.01% pada pintu masuk Husein Sastranegara. Dengan adanya informasi tersebut, diharapkan sektor industri pariwisata terkait dapat membentuk suatu kebijakan terhadap peningkatan pelayanan atau fasilitas yang dapat meminimalisir penurunan jumlah wisatawan.

Kata kunci : Peramalan, Wisatawan Mancanegara, SVM, MAPE, DCA

**FORECASTING NUMBER OF FOREIGN TOURISTS
ARRIVAL TO INDONESIA BASED ON ENTRANCE USING
SUPPORT VECTOR MACHINE (SVM) METHOD**

Student Name : Muhammad Farhan Naufal
NRP : 5213 100 045
Department : Sistem Informasi FTIf-ITS
Supervisor I : Wiwik Anggraeni, S.Si., M.Kom.

ABSTRACT

Tourism is one of the few major industries in the world and is an important factor in the development of the global economy. The more rapid development of tourism with accompanying human needs for recreation increases. Various facilities and infrastructure supporting tourism activities emerge, grow and thrive. Tourism in Indonesia itself is a fairly important economic sector and ranks third in terms of foreign exchange earnings. The number of potential natural and cultural wealth are scattered abundantly made in every area of Indonesia has attractions that can attract both local and foreign travelers.

Indonesia is known as the country that has the largest archipelago in the world with a variety of natural beauty. That way, Indonesia can easily attract tourists, especially for foreign tourists who want to get to know Indonesia. But the number of tourists may change at any time on the impact that can be caused by a certain condition. And in an effort to minimize the number of tourists who are not necessarily, then in this study will be predicted the number of foreign tourists who come to Indonesia based on 6 entrances of the 19 main entrance. At 19 entrances only 6 were chosen due to restricting the research. Where forecasting results and accurate prediction of the estimated number of foreign tourists in the future can provide appropriate strategies for the tourism industry.

In this research, SVM method is used to predict the number of foreign tourists who come to Indonesia from 6 entrances. The entrance is selected based on the cluster of K-means cluster which is divided into 3 clusters ie high, medium and low. Each cluster is then selected only two as an example taken from the highest and lowest values based on the average number of foreign tourists. The use of SVM itself has the advantage of being able to handle linear and non-linear problems. So it can be done to forecast time series data with a variety of existing patterns. In addition, not only predict non-linear problems but also offer fairly good accuracy.

The results obtained from this research trial show that the overall forecasting model is good. The average accuracy of 6 models has a MAPE of about 10% with the smallest value of 4.50% at the entrance of Ngurah Rai. In addition, the results of SVM also have a pretty good accuracy of Directional Change Accuracy (DCA). This is evidenced by the overall average DCA result of 62.64% with the highest score of 64.01% at the entrance of Husein Sastranegara. Given this information, it is expected that the relevant tourism industry sector can form a policy towards the improvement of services or facilities that can minimize the decline in the number of tourists.

Keywords: *Forecasting, Foreign Tourists, SVM, MAPE, DCA*

KATA PENGANTAR

Puji syukur kepada Tuhan yang Maha Esa sehingga penulis dapat menyelesaikan buku tugas akhir dengan judul :

PERAMALAN JUMLAH WISATAWAN MANCANEGERA YANG DATANG KE INDONESIA BERDASARKAN PINTU MASUK MENGGUNAKAN METODE SUPPORT VECTOR MACHINE (SVM)

yang merupakan salah satu syarat kelulusan pada Departemen Sistem Informasi, Fakultas Teknologi Informasi, Institut Teknologi Sepuluh Nopember Surabaya.

Dalam pengerjaan tugas akhir yang berlangsung selama satu semester, penulis ingin mengucapkan terima kasih yang sebesar-besarnya kepada yang senantiasa terlibat secara langsung memberikan bantuan dan dukungan dalam pengerjaan tugas akhir ini :

- Tuhan yang Maha Esa yang telah memberikan kesehatan, kemudahan, kelancaran dan kesempatan untuk penulis hingga dapat menyelesaikan Tugas Akhir ini.
- Kedua orang tua, kakak, dan keluarga yang selalu hadir senantiasa mendoakan dan memberikan kasih sayang serta semangat tiada henti untuk menyelesaikan Tugas Akhir ini.
- Bapak Dr. Ir. Aris Tjahyanto, M.Kom, selaku Ketua Departemen Sistem Informasi ITS, yang telah menyediakan fasilitas terbaik untuk kebutuhan penelitian mahasiswa.
- Ibu Wiwik Anggraeni, S.Si., M.Kom. selaku dosen pembimbing yang telah banyak meluangkan waktu untuk membimbing, mengarahkan, dan mendukung dalam penyelesaian Tugas Akhir.

- Ibu Nur Aini Rakhmawati S.Kom, M.Sc.Eng selaku dosen wali yang telah memberikan arahan terkait perkuliahan di Departemen Sistem Informasi.
- Seluruh dosen pengajar beserta staff dan karyawan di Departemen Sistem Informasi, FTIf ITS Surabaya yang telah memberikan ilmu dan bantuan kepada penulis selama 8 semester ini.
- Teman-teman seperjuangan pada laboratorium RDIB dan Angkatan 2013 Beltranis, yang selalu memberikan semangat positif untuk menyelesaikan Tugas Akhir dengan tepat waktu.

Penulis menyadari bahwa Tugas Akhir ini masih belum sempurna dan memiliki banyak kekurangan di dalamnya. Dan oleh karena itu, penulis meminta maaf atas segala kesalahan yang dibuat penulis dalam buku Tugas Akhir ini. Penulis membuka pintu selebar-lebarnya bagi pihak yang ingin memberikan kritik dan saran, dan penelitian selanjutnya yang ingin menyempurnakan karya dari Tugas Akhir ini. Semoga buku Tugas Akhir ini bermanfaat bagi seluruh pembaca.

Surabaya, 2017

Penulis

DAFTAR ISI

ABSTRAK	v
ABSTRACT	vii
KATA PENGANTAR.....	ix
DAFTAR ISI	xi
DAFTAR TABEL	xv
DAFTAR GAMBAR.....	xvii
BAB I PENDAHULUAN	1
1.1. Latar Belakang Masalah	1
1.2. Perumusan Masalah.....	5
1.3. Batasan Masalah.....	5
1.4. Tujuan Tugas Akhir.....	6
1.5. Manfaat Tugas Akhir.....	6
1.6. Relevansi	7
BAB II TINJAUAN PUSTAKA	9
2.1. Penelitian Sebelumnya	9
2.2. Dasar Teori	11
2.2.1. Perkembangan Pariwisata Internasional	11
2.2.2. Perkembangan Pariwisata Indonesia	12
2.2.3. Wisatawan Mancanegara.....	14
2.2.4. Pentingnya Peramalan dalam Kunjungan Wisatawan Mancanegara.....	14
2.2.5. Peramalan	15
2.2.6. Algoritma <i>K-Means</i>	18

2.2.7.	Uji Normalitas	19
2.2.8.	<i>Support Vector Machine (SVM)</i>	19
2.2.9.	Grid Search Optimization.....	27
2.2.10.	Evaluasi Hasil Peramalan	28
2.2.11.	Evaluasi Turning Point	29
BAB III METODOLOGI		31
3.1.	Diagram Metodologi	31
3.2.	Alur Metodologi	32
3.2.1.	Identifikasi Permasalahan dan Studi Literatur.....	32
3.2.2.	Pengumpulan Data.....	32
3.2.3.	Klasterisasi Data.....	32
3.2.4.	Pre-Processing Data.....	33
3.2.5.	Pemodelan dengan SVM	33
3.2.6.	Peramalan Data.....	35
3.2.7.	Penyusunan Buku Laporan Tugas Akhir.....	35
BAB IV PERANCANGAN		37
4.1.	Pengumpulan Data.....	37
4.2.	Klasterisasi Data.....	38
4.2.1.	Klaster Tinggi.....	43
4.2.2.	Klaster Sedang	45
4.2.3.	Klaster Rendah	46
4.3.	Pra-Proses Data	47
4.3.1.	Uji Normalitas Data.....	47
4.3.2.	Pembagian Data.....	48
BAB V IMPLEMENTASI		51

5.1.	Lingkungan Uji Coba	51
5.2.	Pemodelan SVM dengan R	52
5.2.1.	Mengolah Data Masukan.....	52
5.2.2.	Membangun Model SVM pada R.....	57
5.2.3.	<i>Training</i> dan Pencarian Model SVM terbaik.....	58
5.3.	Peramalan pada periode kedepan	64
BAB VI HASIL DAN PEMBAHASAN		67
6.1.	Hasil Implementasi Model	67
6.1.1.	Pintu Masuk Ngurah Rai	67
6.1.2.	Pintu Masuk Batam	69
6.1.3.	Pintu Masuk Tanjung Uban.....	71
6.1.4.	Pintu Masuk Husein Sastranegara	73
6.1.5.	Pintu Masuk Tanjung Pinang	76
6.1.6.	Pintu Masuk Sepinggan.....	78
6.2.	Analisis Keseluruhan Hasil Uji Coba.....	80
BAB VII KESIMPULAN DAN SARAN		87
7.1.	Kesimpulan.....	87
7.2.	Saran.....	88
DAFTAR PUSTAKA.....		91
BIODATA PENULIS.....		97
LAMPIRAN A		99
LAMPIRAN B		105
LAMPIRAN C		109
LAMPIRAN D		113
LAMPIRAN E.....		147

LAMPIRAN F	161
------------------	-----

DAFTAR TABEL

Table 2.1 Penelitian Sebelumnya mengenai SVM	9
Table 2.2 Penelitian Sebelumnya mengenai SVM	10
Table 2.3 Presentase Devisa Pariwisata untuk Indonesia	12
Table 2.4 Kunjungan Wisatawan Mancanegara ke Indonesia	13
Table 2.5 Jenis kernel SVM	25
Table 2.6 Hasil Parameter Berdasarkan nilai MAPE	29
Table 4.1 Daftar 19 pintu masuk di Indonesia.....	37
Table 4.2 Klasterisasi pada 19 pintu masuk di Indonesia.....	42
Table 4.3 Daftar pintu masuk yang akan diramalkan	43
Table 4.4 Hasil uji normalitas data.....	48
Table 4.5 Pembagian data pelatihan dan data pengujian.....	49
Table 5.1 Perangkat Keras Lingkungan Uji Coba	51
Table 5.2 Perangkat Lunak Lingkungan Uji Coba	51
Table 5.3 Hasil Transformasi Data.....	54
Table 5.4 Data Olah Excel.....	55
Table 5.5 Pengubahan nilai transformasi ke bentuk awal	55
Table 6.1 Parameter Optimal pada dataset Ngurah Rai.....	68
Table 6.2 Uji Performa Model pada dataset Ngurah Rai.....	68
Table 6.3 Tes DCA pada dataset Ngurah Rai.....	68
Table 6.4 Parameter Optimal pada dataset Batam.....	70
Table 6.5 Uji Performa Model pada dataset Batam.....	70
Table 6.6 Tes DCA pada dataset Batam.....	70
Table 6.7 Parameter Optimal pada dataset Tanjung Uban	72
Table 6.8 Uji Performa Model pada dataset Tanjung Uban	72
Table 6.9 Tes DCA pada dataset Tanjung Uban	72
Table 6.10 Parameter Optimal pada dataset Husein Sastranegara..	74
Table 6.11 Uji Performa Model pada dataset Husein Sastranegara	74
Table 6.12 Tes DCA pada dataset Husein Sastranegara	75
Table 6.13 Parameter Optimal pada dataset Tanjung Pinang.....	76
Table 6.14 Uji Performa Model pada dataset Tanjung Pinang....	76
Table 6.15 Tes DCA pada dataset Tanjung Pinang	77
Table 6.16 Parameter Optimal pada dataset Sepinggian	78

Table 6.17 Uji Performa Model pada dataset Sepinggian	78
Table 6.18 Tes DCA pada dataset Sepinggian	79
Table 6.19 Pola data per pintu masuk	80
Table 6.20 Parameter Optimal pada setiap pintu masuk	80
Table 6.21 Hasil Pengelompokan Peramalan	82
Table 6.22 Perbandingan akurasi pada transformasi dan tanpa transf.	82
Table 6.23 Hasil tes DCA per pintu masuk	83
Table 6.24 Perbandingan MAPE dan DCA tiap kluster	84
Table A-1 Pembagian pada dataset Ngurah Rai	99
Table A-2 Pembagian data pada dataset Batam	100
Table A-3 Pembagian data pada dataset Tanjung Uban	101
Table A-4 Pembagian data pada dataset Husein Sastranegara ..	102
Table A-5 Pembagian data pada dataset Tanjung Pinang	103
Table A-6 Pembagian data pada dataset Sepinggian	104
Table C-1 Hasil Transformasi pada dataset Ngurah Rai	109
Table C-2 Hasil Transformasi pada dataset Tanjung Uban	110
Table C-3 Hasil Transformasi pada dataset Tanjung Pinang	111
Table D-1 Training Parameter pada Kluster Tinggi	113
Table D-2 Training Parameter pada Kluster Sedang	124
Table D-3 Training Parameter pada Kluster Rendah	135
Table E-1 Hasil Data Aktual dan Data Prediksi Ngurah Rai	147
Table E-2 Hasil Data Aktual dan Data Prediksi Batam	149
Table E-3 Hasil Data Aktual dan Data Prediksi Tanjung Uban	151
Table E-4 Hasil Data Aktual dan Data Prediksi Husein Sastranegara	153
Table E-5 Hasil Data Aktual dan Data Prediksi Tanjung Pinang	155
Table E-6 Hasil Data Aktual dan Data Prediksi Sepinggian	158
Table F-1 Hasil Peramalan Periode Kedepan dataset Ngurah Rai	161
Table F-2 Hasil Peramalan Periode Kedepan dataset Batam	161
Table F-3 Hasil Peramalan Periode Kedepan dataset Tanjung Uban	162
Table F-4 Hasil Peramalan Periode Kedepan Husein Sastranegara	162
Table F-5 Hasil Peramalan Periode Kedepan dataset Tanjung Pinang	163
Table F-6 Hasil Peramalan Periode Kedepan dataset Sepinggian	163

DAFTAR GAMBAR

Gambar 2.1 Pola Data Time Series	17
Gambar 2.2 Ilustrasi SVM.....	20
Gambar 2.3 Pemisahan dengan kernel	26
Gambar 2.4 Pemisahan dengan kernel 2	26
Gambar 3.1 Metodologi.....	31
Gambar 4.1 Tahap Klasterisasi 1.....	39
Gambar 4.2 Tahap Klasterisasi 2.....	40
Gambar 4.3 Tahap Klasterisasi 3.....	40
Gambar 4.4 Tahap Klasterisasi 4.....	41
Gambar 4.5 Tahap Klasterisasi 5.....	41
Gambar 4.6 Plot data jumlah wisatawan mancanegara pada klaster tinggi periode 2008-2016	44
Gambar 4.7 Plot data jumlah wisatawan mancanegara pada klaster sedang periode 2008-2016.....	45
Gambar 4.8 Plot data jumlah wisatawan mancanegara pada klaster rendah periode 2009-2016.....	46
Gambar 5.1 Tranformasi Data.....	53
Gambar 5.2 Hasil plot data pada R.....	56
Gambar 5.3 Prediksi dalam plot	58
Gambar 5.4 Hasil Parameter Terbaik	60
Gambar 5.5 Hasil Plot nilai prediksi	61
Gambar 5.6 Hasil nilai prediksi.....	62
Gambar 5.7 Hasil perhitungan Microsoft Excel	62
Gambar 5.8 Hasil nilai peramalan 12 bulan kedepan.....	65
Gambar 6.1 Grafik perbandingan data uji Ngurah Rai dan hasil peramalan	69
Gambar 6.2 Grafik perbandingan data uji Batam dan hasil peramalan	71
Gambar 6.3 Grafik perbandingan data uji Tanjung Uban dan hasil peramalan	73
Gambar 6.4 Grafik perbandingan data uji Husein Sastranegara dan hasil peramalan.....	75

Gambar 6.5 Grafik perbandingan data uji Tanjung Pinang dan hasil peramalan	77
Gambar 6.6 Grafik perbandingan data uji Sepingga dan hasil peramalan	79
Gambar B-1 Hasil uji normalitas pada dataset Ngurah Rai.....	105
Gambar B-2 Hasil uji normalitas pada dataset Batam.....	105
Gambar B-3 Hasil uji normalitas pada dataset Tanjung Uban ..	106
Gambar B-4 Hasil uji normalitas pada dataset Husein Sastrane	106
Gambar B-5 Hasil uji normalitas pada dataset Tanjung Pinang	107
Gambar B-6 Hasil uji normalitas pada dataset Sepingga	107

DAFTAR SKRIP

Skrip 5.1	Retrieve Data	56
Skrip 5.2	Plotting Data	56
Skrip 5.3	Install package e1071 & Load library e1071	57
Skrip 5.4	Membangun Model SVM	57
Skrip 5.5	Plot nilai prediksi	57
Skrip 5.6	Optimasi Grid Search.....	59
Skrip 5.7	Kode Melihat Hasil Parameter.....	59
Skrip 5.8	Kode Membuat nilai Prediksi	60
Skrip 5.9	Plot nilai Prediksi.....	60
Skrip 5.10	Kode Melihat angka hasil prediksi	61
Skrip 5.11	Kode untuk memanggil data uji.....	63
Skrip 5.12	Implementasi model terbaik pada data uji	63
Skrip 5.13	Kode memanggil fungsi SVM	64
Skrip 5.14	Input data uji	64
Skrip 5.15	Kode Membuat Data Frame.....	65
Skrip 5.16	Kode untuk memprediksi nilai berikutnya.....	65

BAB I

PENDAHULUAN

Dalam bab pendahuluan ini akan menjelaskan mengenai latar belakang masalah, perumusan masalah, batasan masalah, tujuan tugas akhir, dan manfaat kegiatan tugas akhir. Berdasarkan uraian pada bab ini, diharapkan mampu memberi gambaran umum permasalahan dan pemecahan masalah pada tugas akhir.

1.1. Latar Belakang Masalah

Pariwisata merupakan salah satu dari beberapa industri besar di dunia, dengan kontribusi terhadap total nilai Produk Domestik Bruto (PDB) dunia mencapai 9 persen dan jumlah tenaga kerja yang terserap di industri ini mencapai 200 juta orang [1] . Berdasarkan catatan dari *World Travel Organization (WTO)*, terdapat indikasi bahwa dalam kurun waktu beberapa dekade ke depan, pariwisata sebagai sebuah industri akan berkembang dengan laju yang melebihi jenis industri lainnya. Pada tahun 2012, jumlah perjalanan wisatawan ke berbagai destinasi wisata dunia mencapai jumlah 1,035 milyar dengan adanya pertumbuhan sebesar 5,6 persen per tahun [1]. Perkembangan pariwisata memiliki peran yang sangat penting bagi pembangunan perekonomian suatu wilayah, yaitu sebagai salah satu sumber penerimaan devisa Negara [2]. Selain itu, kepariwisataan terbukti mampu membuka kesempatan kerja, menciptakan peluang usaha dan wirausahawan pada industri ini dan pendukung kepariwisataan, serta meningkatkan kesejahteraan masyarakat [3] . Sehingga kontribusi industri pariwisata di seluruh dunia menjadi sangat penting untuk pembangunan ekonomi global secara signifikan [4].

Sama halnya di Negara lain, pariwisata di Indonesia juga merupakan salah satu sektor yang menjadi motor penggerak dalam pertumbuhan ekonomi Negara [5]. Pada tahun 2009, pariwisata

menempati urutan ketiga dalam hal penerimaan devisa setelah komoditi minyak dan gas bumi serta minyak kelapa sawit [6]. Saat ini, sektor pariwisata Indonesia berkontribusi untuk kira-kira 4% dari total perekonomian dengan harapan dapat menjadi dua kali lipat sebesar 8% dari PDB pada tahun 2019 mendatang [7]. Kekayaan alam dan budaya merupakan komponen penting yang dapat mendorong pariwisata di Indonesia. Seperti diketahui bahwa Indonesia merupakan negara dengan kepulauan terbesar dimana memiliki 17.508 pulau yang 6.000 di antaranya tidak dihuni [8] . Dari berbagai pulau tersebut, Indonesia menyimpan banyak potensi kekayaan alam dan budaya yang tersebar secara berlimpah untuk dapat dijadikan sebagai objek wisata bagi para wisatawan baik dari lokal maupun mancanegara.

Salah satu indikator perkembangan pariwisata dapat diketahui dari adanya pertumbuhan kunjungan wisatawan mancanegara (wisman), selain dari kunjungan wisata domestik serta pertumbuhan pendapatan dari sektor perdagangan dan hotel. Berdasarkan data dari Badan Pusat Statistik jumlah wisatawan mancanegara pada tahun 2008 hingga 2015 yang datang ke Indonesia mengalami peningkatan secara terus menerus dari total keseluruhan pada 19 pintu masuk utama. Titik utama para wisatawan mancanegara yang datang ke Indonesia lebih banyak melalui Bandara Internasional Ngurah Rai, Soekarno Hatta kemudian Batam [7] .Meskipun begitu pada bulan-bulan tertentu jumlah kedatangan wisatawan mancanegara sempat mengalami penurunan sebesar 1,69% pada Juni 2016 jika dibandingkan dengan periode sama pada tahun sebelumnya [9]. Sehingga Melalui Kementerian Pariwisata dan Ekonomi Kreatif, Indonesia mempromosikan diri sebagai tujuan wisata untuk turis-turis asing dengan kampanye "Wonderful Indonesia". Penting bagi Pemerintah untuk berinvestasi dalam kampanye-kampanye promosi seperti ini untuk menyebarkan citra positif Indonesia ke negara luar serta meningkatkan jumlah turis asing untuk

kedepannya dari tahun-tahun sebelumnya dengan harapan target wisatawan asing pada tahun 2017 dapat mencapai 15 juta [7].

Mengingat pariwisata menjadi sektor ekonomi yang cukup penting bagi devisa Negara serta pariwisata memerlukan investasi dalam banyak aspek, termasuk pembangunan infrastruktur lalu lintas, bandara internasional, fasilitas transportasi umum, hotel wisata, serta fasilitas rekreasi di tempat-tempat wisata, yang semua memerlukan waktu yang lama dalam perencanaan konstruksinya. Dengan begitu, maka perlu adanya suatu strategi yang diharapkan dapat mengantisipasi perubahan-perubahan lingkungan yang dinamis dan menghindari sejauh mungkin dampak negatif yang ditimbulkan seperti penurunan jumlah wisatawan mancanegara ke Indonesia [10]. Salah satu cara dalam melakukan antisipasi tersebut dapat dilakukan dengan peramalan untuk periode di masa yang akan datang. Oleh karena itu penelitian ini bertujuan untuk meramalkan jumlah wisatawan mancanegara yang datang ke Indonesia untuk tahun 2017. Dimana hasil peramalan dan prediksi yang akurat dari perkiraan jumlah wisatawan di masa depan dapat memberikan dasar ilmiah untuk merumuskan strategi yang tepat bagi industri pariwisata.

Beberapa metode telah dikembangkan dalam penelitian untuk meramalkan jumlah wisatawan di masa mendatang. Salah satu metode yang dapat digunakan adalah *Support Vector Machine*. Metode ini merupakan suatu teknik berbasis *machine learning* yang relatif baru untuk melakukan prediksi, baik digunakan dalam kasus klasifikasi maupun regresi, dan sangat populer belakangan ini [11]. *Support Vector Machine* adalah salah satu dari sekian banyak metode yang dapat digunakan untuk menyelesaikan berbagai jenis permasalahan termasuk peramalan [12]. Dalam menyelesaikan sebuah permasalahan, *Support Vector Machine* mampu menangani permasalahan non-linier dengan adanya fungsi kernel yang membuat metode ini dapat digunakan untuk peramalan *time series* [13].

Penelitian mengenai SVM untuk meramalkan jumlah wisatawan sudah pernah dilakukan sebelumnya oleh beberapa peneliti. Pada penelitian yang dilakukan pada tahun 2010 yaitu meramalkan jumlah wisatawan ke Johor Malaysia dengan menggunakan *Group of Method Data Handling* yang dikombinasikan dengan *Least Squares Support Vector Machine* (LSSVM). Kombinasi tersebut dinamakan dengan GLSSVM dan menghasilkan akurasi yang cukup baik [13]. Penelitian berikutnya yang dilakukan pada tahun 2016 yaitu meramalkan jumlah wisatawan ke Hongkong berdasarkan Sembilan Negara . Pada penelitian tersebut dilakukan dengan metode SVM yang dikombinasikan dengan *fuzzy rule* dan didapatkan akurasi peramalan yang lebih baik dari ANN, ARIMA, ES dan Naïve [14]. Kelebihan dari metode ini yaitu dapat menangani permasalahan liner dan non-linier, serta beberapa penelitian juga membuktikan bahwa metode ini memiliki akurasi lebih baik dari banyak metode lainnya. Pada masalah non-linier penting untuk menentukan pemilihan fungsi kernel untuk menghasilkan model *Support Vector Machine* yang baik. Penggunaan metode SVM dirasa tepat dalam meramalkan data jumlah wisatawan mancanegara di Indonesia.

Pada tugas akhir ini akan dilakukan peramalan jumlah wisatawan mancanegara yang datang ke Indonesia berdasarkan pintu masuk dengan menggunakan metode SVM. Hasil dari penelitian ini dapat digunakan oleh Badan Pusat Statistik, Dinas Pariwisata serta industri pariwisata lainnya sebagai sarana untuk mendeteksi secara dini dari pergerakan jumlah wisatawan mancanegara yang masuk ke Indonesia pada setiap bulannya. Dengan harapan informasi tersebut bisa membentuk suatu kebijakan untuk dapat meminimalisir penurunan jumlah wisatawan mancanegara. Selain itu dapat sebagai perencanaan dalam peningkatan kebutuhan para wisatawan mancanegara, dimana dengan menambah layanan atau fasilitas baru yang dibutuhkan dimasa mendatang untuk menarik minat wisatawan asing.

1.2. Perumusan Masalah

Perumusan masalah yang diangkat pada tugas akhir ini adalah:

- a. Bagaimana penerapan metode SVM untuk meramalkan jumlah wisatawan mancanegara yang datang ke Indonesia pada enam pintu masuk?
- b. Bagaimana bentuk model SVM terbaik pada parameter tertentu yang dapat digunakan untuk meramalkan jumlah wisatawan mancanegara yang datang ke Indonesia pada enam pintu masuk yang dipilih?
- c. Bagaimana analisis dari nilai ramalan jumlah wisatawan mancanegara pada enam pintu masuk untuk periode ke depan?
- d. Bagaimana hasil akurasi peramalan jumlah wisatawan mancanegara yang datang ke Indonesia pada enam pintu masuk menggunakan metode SVM?

1.3. Batasan Masalah

Batasan permasalahan dalam tugas akhir ini adalah :

- a. Penelitian ini hanya berfokus pada pembuatan model SVM untuk peramalan jumlah wisatawan mancanegara pada 6 pintu masuk di Indonesia yang dipilih tanpa membedakan Negara asal dari wisatawan mancanegara.
- b. Data yang digunakan adalah data bulanan pada tahun 2008 – 2016 dari situs Badan Pusat Statistik
- c. Peramalan jumlah wisatawan mancanegara yang datang ke Indonesia dilakukan pada periode tahun 2017.

1.4. Tujuan Tugas Akhir

Tujuan dari pengerjaan tugas akhir ini adalah :

- a. Menerapkan Metode SVM untuk mendapatkan hasil peramalan wisatawan mancanegara yang datang ke Indonesia dari enam pintu masuk.
- b. Mendapatkan Model SVM terbaik dengan parameter tertentu untuk peramalan jumlah wisatawan mancanegara yang datang ke Indonesia dari enam pintu masuk.
- c. Menganalisa dari perolehan nilai ramalan jumlah wisatawan mancanegara pada periode ke depan.
- d. Mengetahui tingkat akurasi dari penerapan SVM dalam meramalkan jumlah wisatawan mancanegara yang datang ke Indonesia dari enam pintu masuk.

1.5. Manfaat Tugas Akhir

Manfaat yang diberikan dari tugas akhir ini adalah memberikan informasi yang akurat kepada pihak Badan Pusat Statistik dan Dinas Pariwisata serta industri pariwisata yang ada pada setiap daerah mengenai nilai ramalan jumlah wisatawan mancanegara yang datang ke Indonesia pada periode ke depan untuk setiap pintu masuk. Dengan demikian, pihak-pihak terkait tersebut dapat melakukan perencanaan dan pengambilan keputusan terkait upaya peningkatan jumlah wisatawan yang berdampak pada keuntungan. Selain itu, penelitian tugas akhir ini juga dapat membantu industri pariwisata dari tiap daerah untuk membangun strategi dalam meningkatkan keuntungan seperti menambah dan mengembangkan tempat-tempat wisata dari setiap daerah yang dapat menarik wisatawan mancanegara untuk berkunjung dimasa mendatang

1.6. Relevansi

Indonesia adalah Negara dengan kepulauan terbesar di dunia dengan penduduk yang cukup banyak. Wisata di Indonesia pun semakin maju dengan banyaknya potensi alam yang dapat dikembangkan sebagai tempat untuk rekreasi yang dapat menarik wisatawan mancanegara untuk berkunjung. Setiap tahunnya wisatawan mancanegara yang datang ke Indonesia bisa saja mengalami penurunan dan peningkatan yang tak terduga. Untuk memudahkan dalam mencegah terjadinya penurunan wisatawan mancanegara, maka perlu untuk meramalkan jumlah wisatawan mancanegara di masa mendatang. Penerapan Metode SVM dalam peramalan jumlah wisatawan diharapkan akan menghasilkan angka yang mendekati data aktual, sehingga hasil penelitian ini bisa digunakan sebagai bahan pengambilan keputusan untuk dapat melakukan tindakan dalam meminimalisir penurunan yang terjadi pada kunjungan wisatawan mancanegara di Indonesia. Pengembangan dari penelitian ini dapat menciptakan sebuah sistem berbasis SVM ataupun metode lainnya dalam memperkirakan jumlah wisatawan mancanegara pada masa mendatang. Sehingga dinas pariwisata, lembaga masyarakat, dan seluruh elemen yang peduli dengan industri pariwisata bisa mempertimbangkan tindakan apa yang akan diambil apabila terjadi penurunan pada wisatawan mancanegara seperti peningkatan pelayanan wisata, produk wisata atau investasi wisata lainnya. Penelitian tugas akhir ini termasuk dalam mata kuliah Teknik Peramalan, Statistika, dan Sistem Cerdas, serta topik ini termasuk dalam laboratorium Rekayasa Data dan Intelegensia Bisnis di Departemen Sistem Informasi

(Halaman ini sengaja dikosongkan)

BAB II TINJAUAN PUSTAKA

Dalam bab ini akan menjelaskan mengenai penelitian sebelumnya dan dasar teori yang akan dijadikan acuan atau landasan dalam pengerjaan tugas akhir ini.

2.1. Penelitian Sebelumnya

Beberapa penelitian sebelumnya yang dijadikan acuan dalam pengerjaan tugas akhir disajikan dalam tabel 2.1 dan tabel 2.2

Table 2.1 Penelitian Sebelumnya mengenai SVM

Judul Paper	Hybridizing GMDH and Least Squares SVM Support Vector Machine For Forecasting Tourism Demand
Penulis; Tahun	Ruhaidah Samsudin, Puteh Saad, Ani Shabri; 2010
Deskripsi Umum Penelitian	Pada penelitian pertama membahas mengenai peramalan jumlah wisatawan ke Johor Malaysia. Tujuan dari penelitian ini adalah untuk menguji kelayakan model hybrid di peramalan permintaan pariwisata dengan membandingkannya dengan GMDH dan model LSSVM . Penelitian ini menggunakan metode <i>Group of Method Data Handling</i> yang dikombinasikan dengan <i>Least Squares Support Vector Machine</i> (LSSVM) yang dinamakan GLSSVM dalam melakukan peramalan. Pada arsitektur pembelajaran <i>hybrid</i> terdiri dari dua tahapan yaitu Metode GMDH digunakan dalam menentukan nilai <i>input</i> untuk metode LSSVM, kemudian model yang diperoleh dari LSSVM digunakan untuk melakukan peramalan <i>time series</i> . Pada penentuan parameter

	model optimal LSSVM digunakan algoritma <i>grid search</i> . Dari penelitian ini didapatkan bahwa metode GLLSVM memiliki hasil yang cukup akurat dengan menunjukkan hasil yang mendekati sebenarnya atau hanya terjadi kesalahan ramalan sebesar 0.05 % pada model yang diperoleh.
Keterkaitan Penelitian	Penelitian ini dapat menjadi referensi penelitian yang pernah dilakukan terkait peramalan menggunakan metode SVM dalam mengerjakan tugas akhir.

Table 2.2 Penelitian Sebelumnya mengenai SVM

Judul Paper	Forecasting tourism demand by extracting fuzzy Takagi Sugeno rules from trained SVMs
Penulis; Tahun	Xin Xu, Rob Law, Wei Chen, Lin Tang; 2016
Deskripsi Umum Penelitian	Pada penelitian kedua membahas mengenai peramalan jumlah wisatawan mancanegara yang mencakup sembilan Negara yaitu US, Australia, Canada, France, Germany, the UK, Japan, Korea, and Taiwan, China yang datang ke Hongkong. Penelitian ini dilakukan dengan metode SVM yang dikombinasikan dengan <i>fuzzy rule</i> . Dari pemodelan tersebut hal yang pertama dilakukan adalah melakukan pelatihan pada data training dengan mengatur SVM hiper-parameter, seperti parameter kernel. Kemudian model SVM diadopsi dengan metode ekstraksi <i>fuzzy rule</i> dengan model Takagi Sugeno untuk menghasilkan sampel data baru. Lalu mulai menghitung nilai forecast dan akurasi peramalannya. Hasil akurasi peramalan yang diperoleh dengan menggunakan SVM-Rule

	Extraction memiliki MAPE yang paling rendah yaitu dengan rata-rata 13.31% dibandingkan dengan metode lainnya seperti ARIMA, <i>Exponential Smoothing</i> , Naïve , ANN
Keterkaitan Penelitian	Penelitian ini dapat menjadi referensi penelitian yang pernah dilakukan terkait peramalan menggunakan metode SVM dalam mengerjakan tugas akhir.

2.2. Dasar Teori

Berisi teori-teori yang mendukung serta berkaitan dengan tugas akhir yang sedang dikerjakan.

2.2.1. Perkembangan Pariwisata Internasional

Selama enam dekade terakhir, pariwisata telah mengalami ekspansi yang berkelanjutan dan diversifikasi untuk menjadi salah satu industri yang terbesar dan paling cepat berkembang untuk sektor ekonomi di dunia. Banyak tujuan baru telah muncul di berbagai belahan dunia selain dari Eropa dan Amerika. Pariwisata telah membuat pertumbuhan hampir tanpa mengalami gangguan dari waktu ke waktu, meskipun terjadi guncangan sesekali, tetapi masih menunjukkan adanya kekuatan dan ketahanan pada sektor tersebut. Berdasarkan catatan yang diperoleh dari *The United Nation World Tourism Organization* (UNWTO) kedatangan wisatawan internasional telah meningkat dari yang hanya 25 juta secara global pada tahun 1950 menjadi 278 juta pada tahun 1980, 674 juta pada tahun 2000, dan hingga mencapai 1.186.000.000 pada tahun 2015 [15].

Demikian juga, penerimaan pariwisata internasional yang diterima oleh tujuan di seluruh dunia telah melonjak dari US \$2 miliar pada tahun 1950 menjadi US \$104 miliar pada tahun 1980, US \$495.000.000.000 pada tahun 2000, dan hingga mencapai US

\$1.260.000.000.000 pada tahun 2015 yang memberikan sumbangan devisa sekitar 10% dari total PDB [15]. Prospek pariwisata ke depan sangat besar, Berdasarkan prakiraan WTO, jumlah wisatawan internasional tahun 2020 diperkirakan dapat mencapai 1,602 milyar orang dengan pendapatan dunia sebesar US \$2 triliun [1].

2.2.2. Perkembangan Pariwisata Indonesia

Menurut Undang-undang Republik Indonesia Nomor 10 Tahun 2009 Tentang Kepariwisataan, pariwisata adalah gabungan dari berbagai macam kegiatan wisata yang didukung dengan fasilitas dan layanan yang disediakan oleh masyarakat, pengusaha dan pemerintah daerah [16]. Seiring dengan berjalannya waktu, pariwisata di Indonesia makin berkembang dan telah berpengaruh terhadap peningkatan perolehan devisa Negara. Dalam kurun waktu tahun 2007-2011 sektor pariwisata telah menyumbang devisa antara US\$5-8 ribu juta. Tabel 2.3 menunjukkan penerimaan devisa Negara dan presentase kontribusi pariwisata terhadap total penerimaan devisa negara dari wisatawan mancanegara (wisman) yang berkunjung ke Indonesia selama periode tahun 2007-2011. Dan Tabel 2.4 menunjukkan jumlah kunjungan wisatawan mancanegara ke Indonesia.

Table 2.3 Presentase Devisa Pariwisata untuk Indonesia

Tahun	Devisa (Juta US\$)	Presentase terhadap total devisa (%)
2007	5.345,98	4,68
2008	7.347,60	4,55
2009	6.297,99	5,40
2010	7.603,45	4,82

Tahun	Devisa (Juta US\$)	Presentase terhadap total devisa (%)
2011	8.554,39	4,20

Sumber : Kemenparekraf

Pada Tabel 2.3 dapat dilihat bahwa total devisa dan presentase devisa pariwisata cukup berperan penting dengan memberikan sekitar 4-5% bagi Negara. Salah satu faktor yang memajukan sektor pariwisata Negara dapat dilihat dari jumlah kunjungan wisatawan. Jumlah kedatangan wisatawan mancanegara yang berkunjung ke Indonesia menurut pintu masuk antara tahun 2007-2015 terus mengalami peningkatan.

Table 2.4 Kunjungan Wisatawan Mancanegara ke Indonesia

	2007	2008	2009	2010	2011	2012	2013	2014	2015
Wisatawan Asing (dalam juta)	5.51	6.23	6.32	7.00	7.65	8.04	8.80	9.44	9.73

Sumber : Kemenparekraf

Pada Tabel 4 dapat dilihat jumlah kunjungan wisatawan mancanegara ke Indonesia dari kurun waktu tahun 2007 hingga 2015 kian meningkat. Jika dilihat dari perkembangannya, peningkatan yang terjadi cukup signifikan dari yang awalnya sekitar 5.51 juta orang pada tahun 2007 menjadi 9.73 juta orang pada tahun 2015. Dan jika dihitung rata-ratanya, peningkatan yang terjadi sebesar 527.500 orang per tahun.

2.2.3. Wisatawan Mancanegara

Definisi wisatawan mancanegara sesuai dengan rekomendasi *United Nation World Tourism Organization* (UNWTO) adalah setiap orang yang mengunjungi suatu negara di luar tempat tinggalnya, didorong oleh satu atau beberapa keperluan tanpa bermaksud memperoleh penghasilan di tempat yang dikunjungi dan lamanya kunjungan tersebut tidak lebih dari 12 (dua belas) bulan. Definisi ini mencakup dua kategori tamu mancanegara [17], yaitu :

1. Wisatawan (*tourist*) adalah setiap pengunjung seperti definisi di atas yang tinggal paling sedikit dua puluh empat jam, akan tetapi tidak lebih dari dua belas (12) bulan di tempat yang dikunjungi dengan maksud kunjungan antara lain :
 - berlibur, rekreasi dan olahraga
 - bisnis, mengunjungi teman dan keluarga, misi, menghadiri pertemuan, konferensi, kunjungan dengan alasan kesehatan, belajar, dan keagamaan
2. Pelancong (*Excursionist*) adalah setiap pengunjung seperti definisi di atas yang tinggal kurang dari dua puluh empat jam di tempat yang dikunjungi (termasuk *cruise passenger* yaitu setiap pengunjung yang tiba di suatu negara dengan kapal atau kereta api, dimana mereka tidak menginap di akomodasi yang tersedia di negara tersebut).

2.2.4. Pentingnya Peramalan dalam Kunjungan Wisatawan Mancanegara

Kunjungan wisatawan mancanegara memegang peranan penting dalam industri kepariwisataan untuk peningkatan kesejahteraan sosial dan perekonomian Negara. Hal ini perlu diramalkan agar diketahui secara jelas berbagai produk wisata yang dibutuhkan, fasilitas pelayanan terhadap tamu negara, keamanan wisatawan

mancanegara, serta perencanaan investasi wisata [18]. Melihat pentingnya *forecasting* dalam kunjungan wisatawan mancanegara, maka dalam penelitian ini perlu dilakukan *forecasting*.

2.2.5. Peramalan

Peramalan (*forecasting*) merupakan suatu kegiatan untuk memperkirakan apa yang akan terjadi pada masa yang akan datang. Pengumpulan data yang relevan berupa informasi dapat menghasilkan peramalan yang akurat disertai pemilihan teknik peramalan yang tepat maka pemanfaatan informasi data akan diperoleh secara optimal [19].

Peramalan dibedakan menjadi dua jenis yang berbeda berdasarkan metode peramalan yang digunakan, peramalan dibedakan menjadi metode kualitatif dan metode kuantitatif. Metode kualitatif merupakan metode peramalan yang tidak menggunakan data historis masa lalu, lebih didasarkan pada intuisi. Metode kuantitatif merupakan metode peramalan yang menggunakan data historis masa lalu, memanipulasi data historis yang tersedia secara memadai dan tanpa intuisi, metode ini umumnya didasarkan pada analisis statistik [20].

Menurut Makridakis, Wheelwright, dan McGee (1983, h.8-9), peramalan kuantitatif dapat diterapkan bila tiga kondisi terpenuhi yaitu [20]:

- Tersedianya informasi mengenai keadaan waktu yang lalu
- Informasi itu dapat dikuantitatifkan dalam bentuk data numerik
- Dapat diasumsikan bahwa beberapa aspek dari pola di waktu yang lalu akan berlanjut ke waktu yang akan datang

Karakteristik dari peramalan kuantitatif adalah sebagai berikut [21]:

- Melibatkan proyeksi dari masa lalu ke masa mendatang
- Lebih *Scientific*
- Relatif bebas dari persepsi seseorang
- Lebih bersifat Objektif
- Memungkinkan adanya analisis kesalahan / *error analysis*
- Dapat dilakukan secara berulang (*Reproducible*) → Dalam waktu yang sama , hasil yang sama dapat diperoleh dari berbagai teknik yang berbeda

2.2.5.1. Time Frame


Forecasting berdasarkan jangka waktunya dapat dibagi menjadi 3 [22] , yaitu :

1. Jangka Pendek (*Short Term*)
Jangka pendek meliputi kurun waktu mulai dari satu hari sampai satu musim atau dapat sampai satu tahun.
2. Jangka Menengah (*Medium Term*)
Jangka menengah meliputi kurun waktu dari satu musim (kuartal, triwulan atau yang lain) sampai dua tahun.
3. Jangka Panjang (*Long Term*)
Jangka panjang meliputi peramalan untuk kurun waktu minimal lima tahun

2.2.5.2. Pola Data Time Series

Dalam data time series , terdapat 4 jenis pola data dalam peramalan [20], yaitu :

- *Trend* (tren)
Pola data tren menunjukkan pergerakan data cenderung meningkat atau menurun dalam waktu yang lama
- *Seasonality* (musiman)
Pola data musiman terbentuk karena faktor musiman, seperti cuaca dan liburan.
- *Cycles* (siklus)
Pola data siklus terjadi jika variasi data bergelombang pada durasi lebih dari satu tahun dipengaruhi oleh faktor politik, perubahan ekonomi (ekspansi atau kontraksi) yang dikenal dengan siklus usaha.
- *Irregular* (acak)
Pola ini terjadi jika data berfluktuasi di sekitar nilai rata-rata secara acak tanpa membentuk pola yang jelas seperti pola musiman, *trend* ataupun siklus.
Jika digambarkan secara grafik, pola data *time series* dapat dilihat seperti pada Gambar 1.



Gambar 2.1 Pola Data Time Series

Sumber : "Forecasting Quantitative Causal Model Trend Time series", 2015

2.2.6. Algoritma *K-Means*

K-means clustering merupakan salah satu metode data *clustering* non-hirarki yang mengelompokkan data dalam bentuk satu atau lebih cluster/kelompok. Data-data yang memiliki karakteristik yang sama dikelompokkan dalam satu cluster/kelompok dan data yang memiliki karakteristik yang berbeda dikelompokkan dengan cluster/kelompok yang lain. Sehingga data yang berada dalam satu cluster/kelompok memiliki tingkat variasi yang kecil [23].

Langkah-langkah melakukan clustering dengan metode K-Means adalah sebagai berikut [24]:

- a. Pilih jumlah cluster k .
- b. Inisialisasi k pusat cluster yang dilakukan dengan cara random. Pusat-pusat cluster diberi nilai awal dengan angka-angka random.
- c. Alokasikan semua data/ objek ke cluster terdekat. Dalam tahap ini perlu dihitung jarak tiap data ke tiap pusat cluster. Jarak antara satu data dengan satu cluster tertentu akan menentukan suatu data masuk dalam cluster mana.
- d. Untuk menghitung jarak semua data ke setiap titik pusat cluster dapat menggunakan teori jarak Euclidean yang dirumuskan sebagai berikut:

$$D(i, j) = \sqrt{(X_{1i} - X_{1j})^2 + (X_{2i} - X_{2j})^2 + \dots + (X_{ki} - X_{kj})^2} \quad (1)$$

Dimana :

$D(i, j)$ = Jarak data ke i ke pusat cluster j

X_{ki} = Data ke i pada atribut data ke j

X_{kj} = Titik pusat ke j pada atribut ke k

- e. Hitung kembali pusat *cluster* dengan keanggotaan cluster yang sekarang. Pusat *cluster* adalah rata-rata dari semua data/ objek dalam *cluster* tertentu. Dapat juga menggunakan median dari cluster tersebut. Jadi rata-rata (mean) bukan satu-satunya ukuran yang bisa dipakai

- f. Tugaskan lagi setiap objek memakai pusat cluster yang baru. Jika pusat cluster tidak berubah lagi proses *clustering* selesai. Atau, kembali ke langkah nomor 3 sampai pusat *cluster* tidak berubah lagi.

2.2.7. Uji Normalitas

Uji normalitas adalah uji untuk mengukur apakah data kita memiliki distribusi normal ataukah tidak. Model data yang baik adalah model yang memiliki distribusi normal atau mendekati normal, sehingga layak dilakukan pengujian secara statistik [25]. Ketentuan dalam uji normalitas adalah sebagai berikut :

- a) Jika probabilitas $> 0,05$ maka distribusi dari populasi adalah normal.
- b) Jika probabilitas $< 0,05$ maka populasi tidak berdistribusi secara normal”.

Dasar pengambilan keputusan uji normalitas juga dapat dilihat dari plotnya [24]:

- a) Jika data menyebar disekitar garis diagonal dan mengikuti arah garis diagonal, maka dapat disimpulkan bahwa model memenuhi asumsi normalitas.
- b) Jika data menyebar jauh dari garis diagonal dan tidak mengikuti arah garis diagonal, maka dapat disimpulkan bahwa model tidak memenuhi asumsi normalitas”.


Ada beberapa cara uji statistik non parametrik yang digunakan untuk menguji normalitas data . Pada penelitian ini akan digunakan uji statistic Kolmogorov-Smirnov menggunakan *software* Minitab.

2.2.8. Support Vector Machine (SVM)

Support Vector Machine (SVM) dikembangkan oleh Boser, Guyon, Vapnik, dan pertama kali dipresentasikan pada tahun 1992

di *Annual Workshop on Computational Learning Theory* [26]. *Support vector machine* (SVM) merupakan suatu teknik yang relatif baru dan saat ini telah banyak digunakan untuk melakukan prediksi, baik dalam kasus klasifikasi maupun regresi, yang sangat populer belakangan ini. *Support vector machine* berada dalam satu kelas dengan *Neural Network* dalam hal fungsi dan kondisi permasalahan yang bisa diselesaikan, keduanya masuk kedalam kelas *supervised learning* [27].

Secara teoritik *Support Vector Machine* dikembangkan untuk menyelesaikan permasalahan klasifikasi pada dua kelas dengan mencari *hyperplane* terbaik. *Hyperplane* merupakan fungsi untuk memisahkan antara dua kelas pada *input space*, sehingga dari data yang tersebar dapat dilakukan klasifikasi dan analisa regresi. Vapnik menerangkan bahwa setiap permasalahan dapat dimodelkan dengan menggunakan SVM [26]. Ilustrasi SVM dapat dilihat pada Gambar 2.2.



Gambar 2.2 Ilustrasi SVM

Sumber : “*Support Vector Machine Teori dan Aplikasinya dalam BioInformatika*”, 2003

Pada Gambar 2.2(a) menunjukkan alternatif garis pemisah (discrimination boundaries) dimana *pattern* yang tergabung pada *class* -1 disimbolkan dengan warna merah (kotak), sedangkan

pattern pada *class* +1, disimbolkan dengan warna kuning(lingkaran),, sedangkan pada Gambar 2.2(b) diperlihatkan bahwa terdapat garis hyperplane yang tepat berada diantara dua buah kelas. Prinsip dasar dari analisis ini adalah menemukan hyperplane terbaik yakni dengan meminimalkan kesalahan klasifikasi dan memaksimalkan margin geometriknya seperti pada Gambar 2.2(b). Usaha untuk mencari lokasi hyperplane ini merupakan inti dari proses pembelajaran pada SVM [28].

Pengerjaan dengan menggunakan SVM dibagi menjadi 3 [29],yaitu:

2.2.8.1. Support Vector Machine Linier

Prinsip dasar SVM adalah linier classifier, yaitu kasus klasifikasi yang dapat dipisahkan secara linier. Data yang tersedia dinotasikan sebagai $x_i \in R^d$ sedangkan label masing-masing dinotasikan $y_i \in \{-1, +1\}$ untuk $i = 1, 2, \dots, l$, yang mana l adalah jumlah data . Diasumsikan kedua class -1 dan $+1$ dapat terpisah secara sempurna oleh hyperplane berdimensi d , yang didefinisikan [28] :

$$\vec{w} \cdot \vec{x} + b = 0 \quad (2)$$

Pattern x_i yang termasuk class -1 (sampel negatif) dapat dirumuskan sebagai pattern yang memenuhi pertidaksamaan dimana nilai menunjukkan adanya penurunan

$$\vec{w} \cdot \vec{x}_i + b \leq -1 \quad (3)$$

sedangkan pattern x_i yang termasuk class $+1$ (sampel positif) menunjukkan adanya kenaikan pada nilai

$$\vec{w} \cdot \vec{x}_i + b \geq +1 \quad (4)$$

Margin terbesar dapat ditemukan dengan memaksimalkan nilai jarak antara hyperplane dan titik terdekatnya, yaitu $1/\|\vec{w}\|$. Hal ini dapat dirumuskan sebagai Quadratic Programming (QP) problem, yaitu mencari titik minimal persamaan (5), dengan memperhatikan constraint persamaan (6).

$$\min_{\vec{w}} \tau(w) = \frac{1}{2} \|\vec{w}\|^2 \quad (5)$$

$$y_i (\vec{x}_i \cdot \vec{w} + b) - 1 \geq 0, \quad \forall i \quad (6)$$

Problem ini dapat dipecahkan dengan berbagai teknik komputasi, di antaranya *Lagrange Multiplier*

$$L(\vec{w}, b, \alpha) = \frac{1}{2} \|\vec{w}\|^2 - \sum_{i=1}^l \alpha_i (y_i ((\vec{x}_i \cdot \vec{w} + b) - 1)) \quad (7)$$

α_i adalah Lagrange multipliers, yang bernilai nol atau positif ($\alpha_i > 0$). Nilai optimal dari persamaan (7) dapat dihitung dengan meminimalkan L terhadap \vec{w} dan b , dan memaksimalkan L terhadap α_i . Dengan memperhatikan sifat bahwa pada titik optimal gradient $L=0$, persamaan (7) dapat dimodifikasi sebagai maksimalisasi problem yang hanya mengandung α_i saja, sebagaimana seperti pada persamaan (8) di bawah.

Maximize:

$$\sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j \vec{x}_i \cdot \vec{x}_j \quad (8)$$

Subject to:

$$\alpha_i \geq 0 \quad (i = 1, 2, \dots, l) \quad \sum_{i=1}^l \alpha_i y_i = 0 \quad (9)$$

Dari hasil perhitungan ini diperoleh α_i yang kebanyakan bernilai positif. Data yang berkorelasi dengan α_i yang positif inilah yang disebut dengan *support vector*.

Penjelasan di atas berdasarkan asumsi bahwa kedua belah class dapat terpisah secara sempurna oleh hyperplane. Akan tetapi, umumnya dua buah class pada input space tidak dapat terpisah secara sempurna. Hal ini menyebabkan constraint pada persamaan (6) tidak dapat terpenuhi, sehingga optimisasi tidak dapat dilakukan. Untuk mengatasi masalah ini, SVM dirumuskan ulang dengan memperkenalkan teknik softmargin. Dalam *softmargin*,

persamaan (6) dimodifikasi dengan memasukkan *slack variable* ξ_i ($\xi_i > 0$) sebagai berikut .

$$y_i(\vec{x}_i \cdot \vec{w} + b) \geq 1 - \xi_i, \quad \forall i \quad (10)$$

Dengan demikian persamaan (5) diubah menjadi :

$$\min_{\vec{w}} \tau(\vec{w}, \xi) = \frac{1}{2} \|\vec{w}\|^2 + C \sum_{i=1}^l \xi_i \quad (11)$$

Paramater C dipilih untuk mengontrol *tradeoff* antara margin dan *error* klasifikasi . Nilai C yang besar berarti akan memberikan penalti yang lebih besar terhadap *error* klasifikasi tersebut.

2.2.8.2. Support Vector Machine Linier Separation for nonseparable data

Dalam banyak kasus terkadang data tidak dapat dipisahkan dengan menggunakan pemisah linear. Namun, *hyperplane* dengan tingkat *error* yang paling minimum dapat dicari. Sehingga nantinya akan ada variabel *slack* non-negatif $\xi_i, i = 1, \dots, m$. Sehingga diperoleh persamaan dibawah ini:

$$(w \cdot x) + b \geq +1 - \xi_i \rightarrow y_i = +1 \quad (12)$$

$$(w \cdot x) + b \leq -1 + \xi_i \rightarrow y_i = -1 \quad (13)$$

Untuk menentukan *hyperplane* dan meminimasi *error* yang dihasilkan, fungsi tujuan dari permasalahannya adalah sebagai berikut:

$$\min_{w, b, \xi} \frac{1}{2} \|W\|^2 + C \sum_{i=1}^p \xi_i \quad (14)$$

Batasan:

$$y_i(w \cdot x + b) \geq 1 - \xi, \quad \xi \geq 0, \quad i = 1, \dots, p \quad (15)$$

Dalam kasus optimasi untuk data yang *nonseparable*, rumus *Langrange* juga dapat digunakan dalam menemukan solusi yang paling optimal.

$$\max W(\alpha) = \sum_{i=1}^p \alpha_i - \sum_{i=1}^p \sum_{j=1}^p \alpha_i \alpha_j y_i y_j x_i^T x_j \quad (16)$$

Dimana α merupakan pengali *Langrange*

Batasan:

$$\sum_{i=1}^p \alpha_i y_i = 0, 0 \leq \alpha_i \leq C, \quad i = 1, 2, \dots, p \quad (17)$$

2.2.8.3. Support Vector Machine Non-Linear Separation

Pada kasus pemisahan non-linear digunakan fungsi *mapping*, yang biasa disebut dengan fungsi *kernel*. Fungsi ini dapat melakukan *mapping* ruang input dari data *training* ke *feature space* dimensi yang lebih tinggi. Fungsi kernel dapat dilihat pada persamaan berikut (18)

$$(\Phi(x_i) \Phi(x_j)) := k(x_i, x_j) \quad (18)$$

Pada pemisahan nonlinear rumus *Langrange* juga dapat digunakan untuk menemukan solusi.

$$\max W(\alpha) = \sum_{i=1}^p \alpha_i - \sum_{i=1}^p \sum_{j=1}^p \alpha_i \alpha_j y_i y_j k(x_i, x_j) \quad (19)$$

Fungsi apapun yang dapat memenuhi *Mercer's condition* dapat digunakan sebagai fungsi kernel. Pada fungsi kernel, nantinya akan ditentukan nilai parameter seperti nilai C (*cost*) dan γ (*gamma*). Jika diadopsi dengan fungsi kernel Radial (20) , maka fungsi kernel untuk SVM adalah sebagai berikut [30] :

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (20)$$

Fungsi kernel lainnya dapat dilihat pada tabel 2.5 [31]

Table 2.5 Jenis kernel SVM

Jenis Kernel	Definisi
Linear K	$K(x, y) = x \cdot y$
Polynomial $K(x, y)$	$K(x, y) = (x \cdot y + c)^d$
Gaussian RBF	$K(x_i, x_j) = \exp(-\gamma \ x_i - x_j\ ^2)$
Sigmon (tangen hiperbolik)	$K(x, y) = \tanh(\sigma(x, y) + c)$
Invers multiquadric $K(x, y)$	$K(x, y) = \frac{1}{\sqrt{\ x - y\ ^2 + c^2}}$

Fungsi umum yang digunakan untuk non linear SVM dapat dituliskan pada persamaan (21) [30]

$$f(\phi(\vec{x})) = \vec{w} \cdot \phi(\vec{x}) + b \quad (21)$$

Dimana :

x = vektor input


w = parameter bobot

b = bias

Dengan memasukkan *Lagrange multipliers* dan memanfaatkan konstrain pengoptimalan , maka rumus (21) dapat menghasilkan fungsi sebagai berikut:

$$f(x, a_i, a_i^*) = \sum_{i=1}^n (a_i - a_i^*) K(x, x_i) + b \quad (22)$$


Ilustrasi pemisahan nonlinear dapat dilihat pada Gambar 2.3 dan Gambar 2.4.



Gambar 2.3 Pemisahan dengan kernel

Sumber : (<http://onlinesvr.altervista.org/Theory/Theory%20-%2001%20-%20Introduction.htm>)

Gambar 2.3 menunjukkan contoh pemisahan nonlinear pada dua kelas data.



Gambar 2.4 Pemisahan dengan kernel 2

Sumber : (<http://onlinesvr.altervista.org/Theory/Theory%20-%2001%20-%20Introduction.htm>)

Namun, jika pemilihan parameternya salah, maka akan dihasilkan pemisahan yang kurang optimal seperti terlihat pada Gambar 2.4.

SVM untuk melakukan peramalan kedepan dapat menggunakan persamaan (23) [29]

$$f(x) = \text{Sign}\left(\sum_{i=1}^p y_i a_i K(x, x_i) + y_i - w \cdot x_i\right) \quad (23)$$

2.2.9. Grid Search Optimization

Terdapat beberapa algoritma untuk menentukan parameter optimal pada model SVM, salah satunya adalah menggunakan algoritma grid search. Algoritma ini membagi jangkauan parameter yang akan dioptimalkan kedalam grid dan melintasi semua titik untuk mendapatkan parameter yang optimal. Dalam aplikasinya, algoritma grid search harus dipandu oleh beberapa metrik kinerja, biasanya diukur dengan cross-validation pada data training. Oleh karena itu disarankan untuk mencoba beberapa variasi pasangan parameter pada hyperplane SVM. Pasangan parameter yang menghasilkan akurasi terbaik yang didapatkan dari uji crossvalidation merupakan parameter yang optimal. Parameter optimal tersebut yang selanjutnya digunakan untuk model SVM terbaik. Setelah itu, model SVM tersebut digunakan untuk memprediksi data testing untuk mendapatkan generalisasi tingkat akurasi model. Menurut Leidiyana, cross-validation adalah pengujian standar yang dilakukan untuk memprediksi error rate. Data training dibagi secara random ke dalam beberapa bagian dengan perbandingan yang sama kemudian error rate dihitung bagian demi bagian, selanjutnya hitung rata-rata seluruh error rate untuk mendapatkan error rate secara keseluruhan [32].

2.2.10. Evaluasi Hasil Peramalan

Hasil peramalan tidak ada yang dapat dipastikan benar seluruhnya, selalu ada penyimpangan nilai atau perbedaan nilai dengan kenyataan. Berikut adalah evaluasi kinerja yang dilakukan untuk mengetahui seberapa baik peramalan yang dihasilkan atau seberapa kecil penyimpangan yang dialami [31]. Adapun evaluasi yang dilakukan berupa [20]:

2.2.10.1. *Mean Square Error (MSE)*

Mean Square Error (MSE) menghasilkan error yang menunjukkan perbedaan dari hasil estimasi dengan hasil yang diestimasi. Perbedaan yang muncul diakibatkan oleh keacakan pada data atau kurang akuratnya estimasi yang diperoleh.

Rumus MSE secara umum dapat dituliskan :

$$MSE = \frac{\sum_{t=1}^n (x_t - f_t)^2}{n} \times 100\% \quad (24)$$

Dimana :

n = Jumlah Sampel

x_t = Nilai Aktual Indeks pada periode ke-t

f_t = Nilai Prediksi Indeks pada periode ke-t

2.2.10.2. *Mean Absolute Percentage Error (MAPE)*

MAPE merupakan perhitungan yang menunjukkan nilai absolut rata-rata perbedaan antara nilai aktual dan nilai prediksi. Hasil peramalan dikatakan semakin akurat jika nilai MAPE semakin kecil.

Rumus MAPE secara umum dapat dituliskan :

$$MAPE = \frac{\sum_{t=1}^n \left| \frac{xt - ft}{xt} \right|}{n} \times 100\% \quad (25)$$

Dimana:

n = Jumlah Sampel

xt = Nilai Aktual Indeks pada periode ke- t

ft = Nilai Prediksi Indeks pada periode ke- t

Tabel 2.6 menunjukkan perbandingan tingkat akurasi hasil peramalan berdasarkan nilai MAPE [33].

Table 2.6 Hasil Parameter Berdasarkan nilai MAPE

MAPE	Hasil Peramalan
<10%	Sangat Baik
10-20%	Baik
20-50%	Layak/ Cukup
>50%	Buruk

2.2.11. Evaluasi Turning Point

Evaluasi *turning point* digunakan untuk memprediksi perubahan arah data. Evaluasi *turning point* yang digunakan pada penelitian tugas akhir ini adalah:

2.2.11.1. Directional Change Accuration (DCA)

DCA merupakan tes nonparametric yang digunakan untuk mengukur keakuratan arah peramalan. Fokus dari DCA adalah untuk membenarkan prediksi perubahan arah pada variabel yang dipertimbangkan. DCA tidak membutuhkan data kuantitatif, hanya memperhatikan tanda \vec{Zt} dan Zt dimana \vec{Zt} adalah nilai prediksi pada periode t

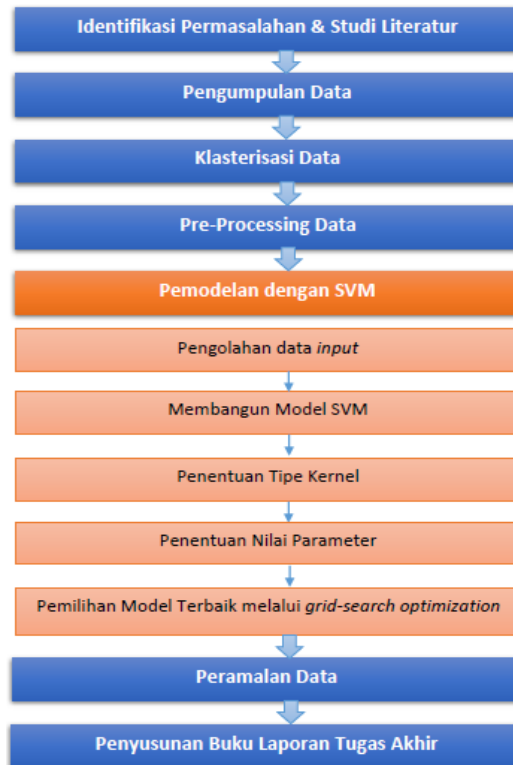
sedangkan Z_t adalah nilai aktual pada periode t . Sehingga hanya perlu melihat apakah arah data berubah dari rendah ke tinggi yang ditandai dengan (+) ataupun sebaliknya (-) pada nilai prediksi. Kemudian menentukan berapa jumlah tanda yang sama dengan data aktual lalu dibagi dengan total jumlah tanda tersebut [34].

BAB III METODOLOGI

Dalam bab ini menjelaskan terkait metodologi yang akan digunakan sebagai panduan untuk menyelesaikan tugas akhir ini.

3.1. Diagram Metodologi

Gambar 3.1 merupakan alur metodologi untuk tugas akhir menggunakan metode *SVM*:



Gambar 3.1 Metodologi

3.2. Alur Metodologi

Berdasarkan pada diagram alur metodologi pada sub bab sebelumnya, di bawah ini merupakan penjelasan dari setiap prosesnya

3.1.1. Identifikasi Permasalahan dan Studi Literatur

Pada proses ini dilakukan identifikasi masalah untuk lebih memahami permasalahan yang terjadi terkait jumlah wisatawan mancanegara di Indonesia. Dengan memahami permasalahan, maka dapat digunakan untuk menentukan solusi yang akan diusulkan. Sedangkan tahapan Studi Literatur digunakan untuk mencari metode penyelesaian yang akan digunakan dalam pengerjaan tugas akhir. Dengan melihat penelitian-penelitian yang memiliki hubungan dengan tugas akhir.

3.1.2. Pengumpulan Data

Pada tahap ini dilakukan proses pengumpulan data-data yang akan digunakan dalam tugas akhir ini. Data yang digunakan adalah data bulanan jumlah wisatawan mancanegara yang datang ke Indonesia pada tahun 2008-2016 . Data tersebut diperoleh dari situs resmi Badan Pusat Statistik mengenai jumlah wisatawan mancanegara berdasarkan 19 pintu masuk di Indonesia periode tahun 2008-2016.

3.1.3. Klasterisasi Data

Dari 19 pintu masuk kemudian dilakukan klasterisasi dengan algoritma *K-Means*. *K-Means* merupakan salah satu metode data clustering non hirarki yang berusaha mempartisi data yang ada ke dalam bentuk satu atau lebih cluster/kelompok. Metode ini mempartisi data ke dalam cluster/kelompok sehingga data yang memiliki karakteristik sama dikelompokkan ke dalam satu cluster yang sama mengacu pada sub bab 2.2.6 .

Pada 19 pintu masuk tersebut dibagi menjadi tiga kluster yaitu Tinggi, Sedang, dan Rendah berdasarkan rata-rata jumlah wisatawan mancanegara. Dari masing-masing kluster kemudian dipilih 2 sebagai *sample* berdasarkan nilai tertinggi dan terendah untuk diramalkan, sehingga total ada 6 pintu masuk.

3.1.4. Pre-Processing Data

Pada tahapan Pra-Processing, data dipersiapkan agar siap dilakukan pemrosesan lebih lanjut seperti *cleaning* data yaitu untuk menghapus data ganda, memeriksa data yang tidak konsisten, serta penanganan data yang hilang atau *missing*. Selain itu juga melakukan uji normalitas data. Data juga dibagi dalam dua bagian, yaitu data pelatihan dan data pengujian dengan presentase 70:30 dari 6 pintu masuk yang dipilih. Lalu data disimpan dalam format yang siap untuk diolah.

3.1.5. Pemodelan dengan SVM

Pada tahap ini mulai dilakukan *training* SVM pada data latih dengan proses pembelajaran untuk model *Support Vector Machine*. Hal yang terlebih dahulu dilakukan yaitu dengan menentukan tipe kernel dan nilai parameter. Jika model terbaik pada data telah terpilih berdasarkan hasil algoritma *grid-search* maka bisa untuk dilakukan peramalan.

Tahapan pemodelan SVM adalah sebagai berikut :

3.1.5.1. Pengolahan data *input*

Dalam tahapan ini data diolah terlebih dahulu sebelum digunakan lebih lanjut. Hal yang perlu dilakukan yaitu melakukan transformasi data terlebih dahulu untuk pintu masuk yang tidak memenuhi asumsi normalitas. Setelah itu data disimpan dalam format csv dan siap untuk diimplementasikan pada aplikasi R.

3.1.5.2. Membangun Model SVM

Dalam tahapan ini data yang telah diolah akan dibangun model SVM awal dengan aplikasi R. Hal tersebut meliputi penambahan *package* terlebih dahulu untuk model SVM yaitu *e1071*. Kemudian untuk membentuk model awal perlu dilakukan pemanggilan *library* (*e1071*) tersebut. Selanjutnya mulai membuat model SVM dari data latih yang telah dimuat sebelumnya. Dari data tersebut sistem akan menampilkan nilai setiap prediksi yang dibuat oleh model berdasarkan data tersebut. Model ini hanya merupakan bentuk awal (*default*) dari model SVM sehingga belum ditentukan tipe kernel dan nilai parameternya. Agar mendapat hasil yang maksimal maka dapat dilanjutkan di langkah berikutnya untuk melakukan pelatihan model.

3.1.5.3. Penentuan tipe kernel

Tipe kernel memiliki beberapa macam dimana yang paling banyak digunakan dalam melakukan penelitian adalah *Radial Basis Function*. Sehingga dalam penelitian ini digunakan tipe kernel RBF karena kemampuannya untuk memberikan performa yang akurat [12].

3.1.5.4. Penentuan nilai parameter

Pada tahap ini dilakukan penentuan *ranges* nilai parameter dari kernel yang dipilih sebelumnya. Penentuan nilai parameter pada *epsilon*, C (*cost*) dan γ (*gamma*) dilakukan dengan implementasi algoritma *grid-search*. *Grid-search* akan melatih banyak pasangan model dari *range* nilai yang telah ditentukan.

3.1.5.5. Pemilihan Model Terbaik melalui *grid-search*

Pada tahapan ini dilakukan pemilihan model terbaik dari data latih yang sudah melewati proses pembelajaran SVM, dengan nilai parameter yang paling baik dari hasil algoritma *grid-search*. Kemudian model tersebut dapat diimplementasikan untuk data uji.

Serta dilakukan perhitungan nilai MAPE kemudian tes DCA untuk data latih dan data uji.

3.1.6. Peramalan Data

Tahap ini dilakukan ketika sudah mendapatkan model SVM terbaik. Model SVM tersebut akan digunakan untuk melakukan peramalan pada data jumlah wisatawan mancanegara di Indonesia pada periode berikutnya.

3.1.7. Penyusunan Buku Laporan Tugas Akhir

Tahapan terakhir adalah pembuatan laporan tugas akhir sebagai bentuk dokumentasi atas terlaksananya tugas akhir ini. Di dalam laporan tersebut mencakup:

a. Bab I Pendahuluan

Dalam bab ini dijelaskan mengenai latar belakang, rumusan dan batasan masalah, tujuan dan manfaat pengerjaan tugas akhir ini.

b. Bab II Tinjauan Pustaka dan Dasar Teori

Dijelaskan mengenai penelitian-penelitian serupa yang telah dilakukan serta teori – teori yang menunjang permasalahan yang dibahas pada tugas akhir ini

c. Bab III Metodologi

Dalam bab ini dijelaskan mengenai tahapan – tahapan apa saja yang harus dilakukan dalam pengerjaan tugas akhir

d. Bab IV Perancangan

Bab ini menjelaskan tentang rancangan penelitian tugas akhir untuk membuat model peramalan. Bab ini berisikan proses pengumpulan data, gambaran data masukan dan keluaran, serta pengolahan data

e. Bab V Implementasi

Bab ini menjelaskan proses pelaksanaan penelitian dan pembuatan model yang akan digunakan untuk peramalan.

f. Bab VI Hasil dan Pembahasan

Bab ini berisikan hasil dan pembahasan setelah melakukan implementasi. Hasil yang akan dijelaskan adalah hasil uji coba model, validasi model, hasil peramalan untuk periode yang akan datang.

g. Bab VII Kesimpulan dan Saran

Pada bab ini dibahas mengenai kesimpulan dari semua proses yang telah dilakukan dan saran yang dapat diberikan untuk pengembangan yang lebih baik.

BAB IV

PERANCANGAN

Pada bab ini dijelaskan bagaimana rancangan dari penelitian tugas akhir yang dilakukan dengan meliputi subjek dan objek penelitian, pemilihan subjek, dan objek yang diteliti, dan bagaimana penelitian dilaksanakan.

4.1. Pengumpulan Data

Hal pertama yang dilakukan dalam penelitian adalah pengumpulan data yang bersifat mutlak dikarenakan data digunakan sebagai sumber utama dalam penelitian ini. Data yang digunakan dalam tugas akhir ini adalah data jumlah wisatawan mancanegara yang datang ke Indonesia dari 19 pintu masuk. Data tersebut diperoleh melalui situs resmi Badan Pusat Statistik terkait jumlah wisatawan mancanegara ke Indonesia periode 2008 hingga 2016 pada setiap bulannya.

Data yang diambil berupa laporan angka dari masing-masing jumlah wisatawan mancanegara pada 19 pintu masuk. Setelah semua data asli (mentah) telah terkumpul seluruhnya kemudian dilakukan klasterisasi dengan tujuan membatasi data yang ada dengan hanya meramalkan untuk 6 pintu masuk di Indonesia. Klasterisasi dilakukan dengan algoritma *K-Means*. Rincian 19 pintu masuk di Indonesia yang dilalui wisatawan mancanegara dapat dilihat pada tabel 4.1.

Table 4.1 Daftar 19 pintu masuk di Indonesia

No	Pintu Masuk	Kota	Provinsi
1	Soekarno Hatta	Jakarta	DKI Jakarta
2	Tanjung Priok	Jakarta	DKI Jakarta
3	Husein Sastranegara	Bandung	Jawa Barat
4	Adi Sumarmo	Solo	Jawa Tengah
5	Juanda	Surabaya	Jawa Timur

No	Pintu Masuk	Kota	Provinsi
6	Adi Sucipto	Yogyakarta	D.I Yogyakarta
7	Kualanamu	Medan	Sumatera Utara
8	Minangkabau	Padang	Sumatera Barat
9	Tanjung Pinang	Batam	Kepulauan Riau
10	Batam	Batam	Kepulauan Riau
11	Tanjung Uban	Bintan	Kepulauan Riau
12	Balai Karimun	Karimun	Kepulauan Riau
13	Sultan Syarif Kasim II	Pekanbaru	Riau
14	Ngurah Rai	Denpasar	Bali
15	Lombok	Mataram	Nusa Tenggara Barat
16	Sepinggan	Balikpapan	Kalimantan Timur
17	Entikong	Pontianak	Kalimantan Barat
18	Sam Ratulangi	Manado	Sulawesi Utara
19	Makassar	Makassar	Sulawesi Selatan

4.2. Klasterisasi Data

Pada 19 pintu masuk tersebut dibagi menjadi tiga klaster yaitu Tinggi, Sedang, dan Rendah berdasarkan rata-rata jumlah wisatawan mancanegara. Kemudian masing-masing klaster dipilih 2 dari nilai tertinggi dan terendah untuk diramalkan sehingga total ada 6 pintu masuk. Dalam penelitian ini menggunakan *tools* XLStat yang dapat terkoneksi dengan Microsoft Excel. Sebelumnya telah dijelaskan mengenai pengertian dari algoritma K-Means yang mengacu pada sub bab 2.2.6.

Adapun langkah-langkah dalam melakukan klasterisasi adalah sebagai berikut :

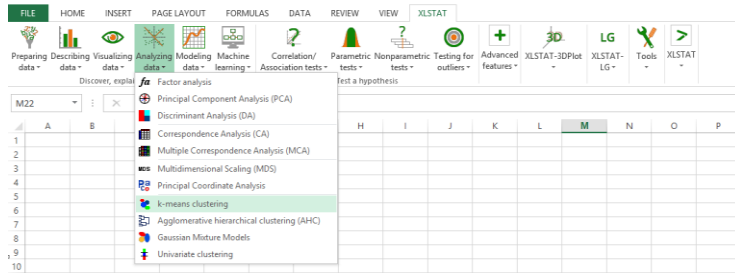
- Hal pertama yang dilakukan adalah penambahan *add-ins* terlebih dahulu. *Add-ins* tersebut yakni XLStat yang dapat diunduh melalui <https://www.xlstat.com/en/download>.
- Kemudian menyiapkan data yang akan diklasterisasi seperti pada gambar 4.1

The screenshot shows the Microsoft Excel interface with the XLStat add-in menu visible. The data table is as follows:

	A	B	C	D	E	F	G	H
1	Pintu Masuk	Rata-Rata Jumlah Wisman						
2		263483						
3	Ngurah Rai	165588						
4	Soekarno Hatta	103477						
5	Batam	26383						
6	Tanjung Uban	16034						
7	Juanda	15759						
8	Kualanamu	11758						
9	Husein Sastranegara	8478						
10	Tanjung Pinang	8397						
11	Balai Karimun	5923						
12	Adi Sucipto	5346						
13	Tanjung Priok	3418						
14	Minangkabau	3257						
15	Lombok	1959						
16	Entikong	1928						
17	Sam Ratulangi	1893						
18	Sultan Syarif Kasim II	1374						
19	Adi Sumarmo	1240						
20	Makassar	1052						
21	Sepinggagan							

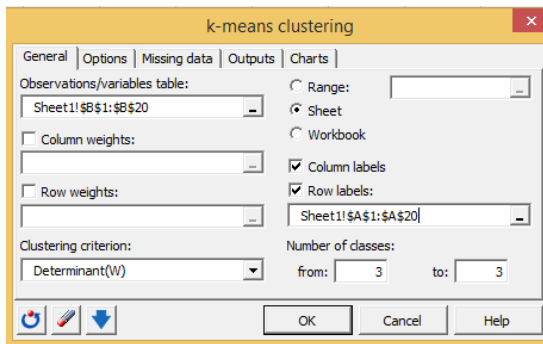
Gambar 4.1 Tahap Klasterisasi 1

- Buka aplikasi Microsoft Excel kemudian klik tab XLStat . Ketika muncul tampilan seperti pada gambar 4.2 lalu pilih menu *Analyzing data* → *k-means clustering*.



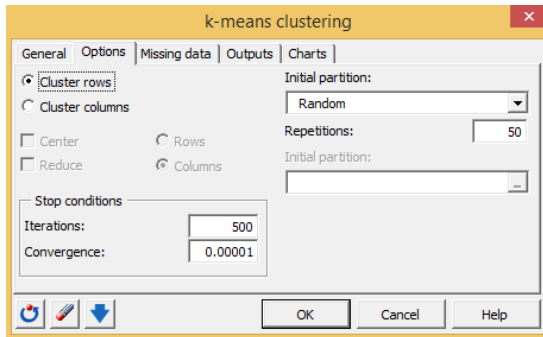
Gambar 4.2 Tahap Klasterisasi 2

- Lalu isikan “*Observation/variables table*” dengan data yang akan diklasterisasi yaitu dari rata-rata jumlah wisatawan mancanegara. Kemudian isikan “*Row labels*” dengan daftar pintu masuk serta jumlah klaster yang diinginkan pada “*Number of classes*” seperti pada gambar 4.3.



Gambar 4.3 Tahap Klasterisasi 3

- Setelah itu bisa juga mengatur jumlah iterasi yang diinginkan pada menu *Options* seperti pada gambar 4.4 , tetapi disini menggunakan yang *default* saja. Lalu klik OK.



Gambar 4.4 Tahap Klasterisasi 4

- Hasil dari klasterisasi yang telah dilakukan dapat dilihat pada *sheet* baru yang muncul secara otomatis dengan nama *k-means*. Pada gambar 4.5 terlihat bahwa terdapat 3 pintu masuk pada klaster tinggi, 4 pintu masuk pada klaster sedang dan 12 sisanya masuk pada klaster rendah.

Results by object:		
Observation	Class	Distance to centroid
Ngurah Rai	1	85966.466
Soekarno Hatta	1	11927.877
Batam	1	74038.590
Tanjung Uban	2	8899.070
Juanda	2	1449.629
Kualanamu	2	1724.407
Husein Sastranegara	2	5725.034
Tanjung Pinang	3	4789.402
Balai Karimun	3	4708.098
Adi Sucipto	3	2234.577
Tanjung Priok	3	1657.439
Minangkabau	3	271.117
Lombok	3	431.718
Entikong	3	1729.533
Sam Ratulangi	3	1760.829
Sultan Syarif Kasim II	3	1795.404
Adi Sumarmo	3	2314.644
Makassar	3	2449.172
Sepinggan	3	2637.098

Gambar 4.5 Tahap Klasterisasi 5

Hasil klasterisasi dengan menggunakan *K-Means* dapat dilihat pada tabel 4.2.

Table 4.2 Klasterisasi pada 19 pintu masuk di Indonesia

No	Pintu Masuk	Rata-Rata Jumlah Wisman	Klaster
1	Ngurah Rai	263.483	Tinggi
2	Soekarno Hatta	165.588	Tinggi
3	Batam	103.477	Tinggi
4	Tanjung Uban	26.383	Sedang
5	Juanda	16.034	Sedang
6	Kualanamu	15.759	Sedang
7	Husein Sastranegara	11.758	Sedang
8	Tanjung Pinang	8.478	Rendah
9	Balai Karimun	8.397	Rendah
10	Adi Sucipto	5.923	Rendah
11	Tanjung Priok	5.346	Rendah
12	Minangkabau	3.418	Rendah
13	Lombok	3.257	Rendah
14	Entikong	1.959	Rendah
15	Sam Ratulangi	1.928	Rendah
16	Sultan Syarif Kasim II	1.893	Rendah
17	Adi Sumarmo	1.374	Rendah
18	Makassar	1.240	Rendah
19	Sepinggan	1.052	Rendah

Dari hasil klaster tersebut dipilih 6 pintu masuk dengan mengambil 2 dari masing-masing klaster. Pemilihan 2 pintu masuk dari tiap klaster dipilih berdasarkan jumlah wisman tertinggi dan terendah.

Sehingga hasil pemilihan pintu masuk yang akan diramalkan dapat dilihat pada tabel 4.3.


Table 4.3 Daftar pintu masuk yang akan diramalkan

No	Pintu Masuk	Rata-Rata Jumlah Wisman	Klaster
1	Ngurah Rai	263.483	Tinggi
2	Batam	103.477	Tinggi
3	Tanjung Uban	26.383	Sedang
4	Husein Sastranegara	11.758	Sedang
5	Tanjung Pinang	8.478	Rendah
6	Sepinggan	1.052	Rendah

Berikut adalah hasil dari grafik plot pada ketiga klaster yang meliputi pintu masuk Ngurah Rai, Batam, Tanjung Uban, Husein Sastranegara, Tanjung Pinang dan Sepinggan :

4.2.1. Klaster Tinggi

Data jumlah wisatawan mancanegara pada pintu masuk Ngurah Rai dan Batam diperoleh dalam periode tahun 2008-2016 untuk setiap bulan. Jika ditunjukkan dalam bentuk grafik plot maka dapat dilihat pada Gambar 4.6.




Gambar 4.6 Plot data jumlah wisatawan mancanegara pada klaster tinggi periode 2008-2016

Berdasarkan grafik plot pada gambar 4.6 menunjukkan bahwa pada pola data Ngurah Rai cenderung memiliki pola tren naik dan disertai adanya pola musiman atau dapat disebut *seasonal trend*. Sedangkan untuk pola data Batam cenderung memiliki pola musiman atau *seasonal* dengan adanya pola yang berulang pada tiap periode. Dari gambar 4.6 juga terlihat bahwa grafik memiliki dua sumbu, yaitu x dan y. Dimana sumbu x menyatakan waktu dalam bulan sedangkan sumbu y menyatakan jumlah wisatawan mancanegara.

4.2.2. Klaster Sedang

Data jumlah wisatawan mancanegara pada pintu masuk Tanjung Uban dan Husein Sastranegara diperoleh dalam periode tahun 2009-2016 untuk setiap bulan. Jika ditunjukkan dalam bentuk grafik plot maka dapat dilihat pada Gambar 4.7.




Gambar 4.7 Plot data jumlah wisatawan mancanegara pada klaster sedang periode 2009-2016

Berdasarkan grafik plot pada gambar 4.7 menunjukkan bahwa pada pola data Tanjung Uban cenderung memiliki pola yang horizontal dengan adanya fluktuasi naik dan turun yang konstan. Sedangkan untuk pola data Husein Sastranegara cenderung memiliki pola yang

irregular/acak. Dari gambar 4.7 juga terlihat bahwa grafik memiliki dua sumbu, yaitu x dan y. Dimana sumbu x menyatakan waktu dalam bulan sedangkan sumbu y menyatakan jumlah wisatawan mancanegara.

4.2.3. Klaster Rendah

Data jumlah wisatawan mancanegara pada pintu masuk Tanjung Pinang dan Sepinggang diperoleh dalam periode tahun 2008-2016 untuk setiap bulan. Jika ditunjukkan dalam bentuk grafik plot maka dapat dilihat pada Gambar 4.8.



Gambar 4.8 Plot data jumlah wisatawan mancanegara klaster rendah periode 2008-2016

Berdasarkan grafik plot pada gambar 4.8 menunjukkan bahwa pada pola data Tanjung Pinang cenderung memiliki pola yang horizontal dengan adanya fluktuasi naik dan turun yang konstan. Sedangkan untuk pola data Sepinggian cenderung memiliki pola yang *irregular*/acak. Dari gambar 4.8 juga terlihat bahwa grafik memiliki dua sumbu, yaitu x dan y. Dimana sumbu x menyatakan waktu dalam bulan sedangkan sumbu y menyatakan jumlah wisatawan mancanegara.

4.3. Pra-Proses Data

Pada tahapan Pra-Proses data dipersiapkan dengan melakukan *cleaning* data yaitu memiliki tujuan agar menghilangkan data-data yang hilang (*missing value*) ataupun data-data yang dianggap tidak normal . Dikarenakan pada data penelitian yang bersumber dari BPS tidak terdapat *missing values* maka tahapan tersebut akan dilewati. Selain itu juga melakukan uji normalisasi data yang bisa dilanjutkan dengan transformasi data. Data juga dibagi dalam dua bagian, yaitu data pelatihan dan data pengujian dengan presentase 70:30 dari 6 pintu masuk yang dipilih. Lalu data disimpan dalam format yang siap untuk diolah.

4.3.1. Uji Normalitas Data

Uji Normalitas merupakan uji untuk menentukan apakah data berdistribusi normal atau tidak mengacu pada sub bab 2.2.7. Jika data tidak normal maka dibutuhkan proses untuk merubah data yang berbeda kedalam sebuah jangkauan nilai yang sudah ditentukan. Adapun tujuan normalisasi yaitu untuk mengurangi perbedaan data yang sangat jauh . Pada penelitian ini akan dilakukan pengujian normalitas pada 6 pintu masuk di Indonesia dengan menggunakan software statistik *Minitab* yang memiliki menu '*Normality Test*'. Jika data telah berdistribusi secara normal maka data tersebut siap untuk diolah lebih lanjut pada tahapan pemodelan SVM, dan jika belum maka perlu dilakukan

transformasi terlebih dahulu. Uji normalitas dengan *Minitab* untuk setiap pintu masuk dapat dilihat pada lampiran B.

Hasil dari uji normalitas data secara keseluruhan dapat dilihat pada tabel 4.4 berikut :

Table 4.4 Hasil uji normalitas data

Pintu Masuk	P-Value	Hasil	Keterangan
Ngurah Rai	0.010	< 0.05	Tidak Normal
Batam	0.069	> 0.05	Normal
Tanjung Uban	0.040	< 0.05	Tidak Normal
Husein Sastranegara	0.054	> 0.05	Normal
Tanjung Pinang	0.010	< 0.05	Tidak Normal
Sepinggan	0.108	> 0.05	Normal

Dapat dilihat pada tabel 4.4 terdapat 3 pintu masuk yaitu Batam, Husein Sastranegara dan Sepinggan menunjukkan bahwa data telah berdistribusi normal . Sedangkan 3 pintu masuk lainnya yakni Ngurah Rai, Tanjung Uban dan Tanjung Pinang tidak berdistribusi normal sehingga perlu ditransformasi terlebih dahulu.

Dalam membuat data agar berdistribusi secara normal maka dapat dilakukan transformasi dengan menggunakan *tools* SPSS atau juga bisa dengan fungsi pada Microsoft excel. Diperlukan normalisasi karena dapat membantu SVM dalam memberikan hasil yang lebih baik [12]. Cara untuk mengimplementasikannya akan dijelaskan lebih lanjut pada tahapan implementasi di bab v.

4.3.2. Pembagian Data

Pembagian data dilakukan dengan membagi menjadi 2 bagian yaitu data pelatihan dan data pengujian dengan presentase 70:30 dari 6 pintu masuk yang dipilih. Pada data pelatihan akan digunakan dalam menentukan model SVM yang nantinya digunakan untuk

peramalan. Model SVM akan dipilih yang terbaik sebelum diaplikasikan pada data pengujian. Dikarenakan periode data yang didapatkan untuk pintu masuk berbeda, maka pada penelitian ini terdapat pembagian data yang berbeda yaitu dari periode tahun 2008-2016 dan 2009-2016 seperti terlihat pada tabel 4.5 . Hasil pembagian data secara rinci dapat dilihat pada lampiran A.

Table 4.5 Pembagian data pelatihan dan data pengujian

Pintu Masuk	Periode	Total Data	Train Set	Test Set
Ngurah Rai	2008-2016	108	76	32
Batam	2008-2016	108	76	32
Tanjung Pinang	2008-2016	108	76	32
Sepinggan	2008-2016	108	76	32
Tanjung Uban	2009-2016	96	67	29
Husein Sastranegara	2009-2016	96	67	29

Pembagian datanya jika dijabarkan secara rinci adalah sebagai berikut:

- Periode tahun 2008 - 2016 :
 - a. Train Set : Januari 2008 - April 2014
 - b. Test Set : Mei 2014 - Desember 2016
- Periode tahun 2009 – 2016 :
 - a. Train Set : Januari 2009 - Juli 2014
 - b. Test Set : Agustus 2014 - Desember 2016

(Halaman ini sengaja dikosongkan)

BAB V

IMPLEMENTASI

Pada bab ini dijelaskan secara terperinci dari proses pelaksanaan penelitian , yaitu implementasi model peramalan meliputi penjabaran lingkungan uji coba, proses normalisasi data hingga tahap pemodelan SVM dengan aplikasi R.

5.1. Lingkungan Uji Coba

Dalam tugas akhir ini, lingkungan uji coba menjelaskan mengenai lingkungan pengujian yang digunakan untuk melakukan implementasi. Lingkungan uji coba meliputi perangkat keras, perangkat lunak yang digunakan. Pemodelan peramalan dilakukan menggunakan PC berspesifikasi seperti yang ditunjukkan pada tabel 5.1.

Table 5.1 Perangkat Keras Lingkungan Uji Coba

Perangkat Keras	Spesifikasi
Jenis	Laptop
Processor	Intel® Pentium® M
RAM	2 GB
Hard Disk Drive	320 GB

Selain itu juga terdapat lingkungan perangkat lunak yang digunakan dalam uji coba model. Tabel 5.2 berikut adalah daftar perangkat lunak yang digunakan dalam uji coba.

Table 5.2 Perangkat Lunak Lingkungan Uji Coba

Perangkat Lunak	Fungsi
Windows 8.1 64 bit	Sistem Operasi

Perangkat Lunak	Fungsi
R x64 3.3.3	Membuat Kode Program
Ms. Office Excel 2013	Mengelola Data
Minitab & SPSS	Menormalisasi Data

5.2. Pemodelan SVM dengan R

Hal pertama yang dilakukan adalah melakukan instalasi aplikasi R perangkat keras yang digunakan. Support Vector Machine dalam penelitian ini bertujuan untuk memprediksi nilai-nilai nyata dari suatu data daripada untuk menentukan kelas. Support Vector Machine mengakui keberadaan non-linearitas dalam data dan menyediakan model prediksi yang cukup baik [35] .

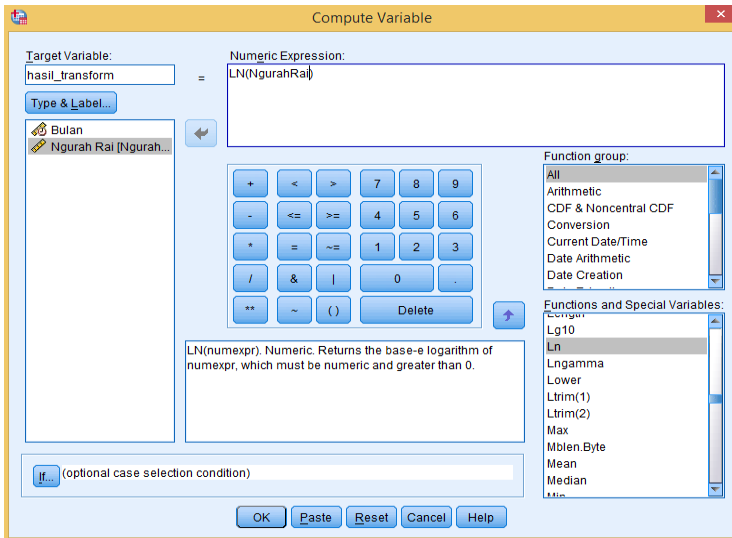
5.2.1. Mengolah Data Masukan

Proses pertama dalam pembangunan pemodelan dengan SVM adalah dengan menginputkan data pembangun menggunakan R. Data tersebut terdiri dari data latih dan data uji. Data latih digunakan untuk mencari model terbaik yang nantinya akan diimplementasikan ke data uji untuk melihat akurasi dan melakukan peramalan.

5.2.1.1. Normalisasi Data

Sebelumnya telah dilakukan uji normalitas untuk melihat pada data manakah yang perlu dilakukan normalisasi/transformasi agar data berdistribusi secara normal. Dalam penelitian ini pintu masuk Ngurah Rai, Tanjung Uban dan Tanjung Pinang perlu dilakukan transformasi terlebih dahulu yang digunakan dengan tools SPSS. Untuk melakukan transformasi pada SPSS terdapat pada sub menu *Compute Variable* pada menu *Transform*. Kemudian akan muncul kotak dialog seperti pada gambar 5.1. Pada *target variable* akan terdapat kolom hasil transformasi dan pada *Function and Special*

Variables dapat memilih transformasi yang akan digunakan, salah satunya adalah Ln. Setelah itu, untuk data pintu masuk yang akan ditransformasi dapat diletakkan pada *Numeric expression*.



Gambar 5.1 Tranformasi Data

Hasil dari transformasi dapat ditunjukkan seperti pada tabel 5.3 dimana telah terdapat kolom hasil transformasi. Hasil transformasi secara rinci per pintu masuk dapat dilihat pada lampiran C.

	Bulan	NgurahRai	hasil_transform
1	1-Jan-2008 00:00:00.00	147319.0	11.9
2	1-Feb-2008 00:00:00.00	159681.0	11.9
3	1-Mar-2008 00:00:00.00	159886.0	11.9
4	1-Apr-2008 00:00:00.00	154777.0	11.9
5	1-May-2008 00:00:00.00	167342.0	12.0
6	1-Jun-2008 00:00:00.00	178258.0	12.0
7	1-Jul-2008 00:00:00.00	190662.0	12.1
8	1-Aug-2008 00:00:00.00	195758.0	12.1
9	1-Sep-2008 00:00:00.00	189247.0	12.1
10	1-Oct-2008 00:00:00.00	189142.0	12.1
11	1-Nov-2008 00:00:00.00	172813.0	12.0
12	1-Dec-2008 00:00:00.00	176901.0	12.0
13	1-Jan-2009 00:00:00.00	173919.0	12.0
14	1-Feb-2009 00:00:00.00	146192.0	11.8
15	1-Mar-2009 00:00:00.00	168036.0	12.0
16	1-Apr-2009 00:00:00.00	188189.0	12.1
17	1-May-2009 00:00:00.00	190697.0	12.1
18	1-Jun-2009 00:00:00.00	200503.0	12.2

Table 5.3 Hasil Transformasi Data

5.2.1.2. Pengolahan Data pada Excel

Hasil transformasi tersebut kemudian disalin ke Excel untuk diolah lebih lanjut. Pada tabel 5.4 merupakan data pada excel dimana variable X menunjukkan Bulan yang disusun menjadi angka berurutan agar mudah dibaca pada aplikasi R dan Y menunjukkan jumlah wisatawan mancanegara. Setelah itu disimpan dalam bentuk CSV.

	A	B	C	D	E
1	X	Y			
2		1	11.9		
3		2	11.98		
4		3	11.98		
5		4	11.95		
6		5	12.03		
7		6	12.09		
8		7	12.16		
9		8	12.18		
10		9	12.15		
11		10	12.15		
12		11	12.06		
13		12	12.08		
14		13	12.07		
15		14	11.89		
16		15	12.03		
17		16	12.15		
18		17	12.16		
19		18	12.21		
20		19	12.37		
21		20	12.36		
22		21	12.29		
23		22	12.33		
24		23	12.18		

Table 5.4 Data Olah Excel

Pada tahap ini juga dibedakan data latih dan data uji . Data latih sebanyak 76 data untuk menentukan model SVM terbaik dimana model tersebut akan diimplementasikan ke data uji untuk dilakukan peramalan periode kedepan.

5.2.1.3. Input Data pada R

Ketika membuka jendela kerja R pertama-tama melakukan *Load* data pada csv yang telah tersimpan sebelumnya. Kode programnya seperti pada skrip 5.1 yang dituliskan di “*R Console*”. Dimana pada baris pertama menunjukkan direktori data yang akan dimodelkan dan baris kedua untuk memanggil data berdasarkan nama filenya.


```
> dataDirectory <- "D:/ta/Data/Data per pintu
masuk/Ngurah Rai/"

> data <- read.csv(paste(dataDirectory,
'Ngurah Rai Train Transform.csv', sep=""),
header = TRUE)
```


Skrip 5.1 Retrieve data

Jika ingin melihat grafik plotnya maka dilakukan *plotting* data masukan terlebih dahulu dengan menuliskan kode program seperti pada skrip 5.2 .

```
> plot(data, pch=16)
```

Skrip 5.2 Plotting data

Hasil *plotting* tersebut dapat dilihat seperti ditunjukkan pada gambar 5.2 dimana sumbu X menunjukkan waktu dan sumbu Y menunjukkan jumlah wisatawan mancanegara.



Gambar 5.2 Hasil plot data pada R

5.2.2. Membangun Model SVM pada R

Untuk dapat membuat model SVM dengan R , diperlukan *package* tambahan yaitu *e1071*. Sehingga pastikan untuk *install* terlebih dahulu dan menambahkan *library* (*e1071*) pada baris awal di *workspace*. Cara menambahkan *package* dan melakukan *load library* dapat dituliskan dengan kode program seperti pada skrip 5.3.

```
#Install Package
> install.packages("e1071")

#Load Library
> library(e1071)
```

Skrip 5.3 Install package e1071 & Load library e1071

Selanjutnya membuat model SVM dari data latih yang telah dimuat, lalu mulai menentukan nilai setiap prediksi yang dibuat oleh model berdasarkan data tersebut. Cara melakukannya dapat dituliskan dengan kode program seperti pada skrip 5.4.

```
#Create svm model
> model <- svm(Y ~ X , data)

#Make a prediction for each x
> predictedY <- predict(model, data)
```


Skrip 5.4 Membangun Model SVM

Jika ingin melihat hasil nilai prediksi dalam bentuk plot maka dapat ditampilkan dengan menuliskan kode program seperti pada skrip 5.5 yang diatur dengan warna merah.

```
> points(data$X, predictedY, col = "red",
pch=4)
```

Skrip 5.5 Plot nilai prediksi

Hasil dari nilai prediksi data dalam plot dapat dilihat pada gambar 5.3 yang ditunjukkan dengan titik warna merah, dimana sumbu X menunjukkan waktu dan sumbu Y menunjukkan jumlah wisatawan mancanegara.



Gambar 5.3 Prediksi dalam plot

Hasil nilai prediksi diatas baru ditentukan secara *default* oleh sistem dan belum diatur tipe kernel serta nilai parameternya. Untuk mendapatkan hasil yang maksimal maka perlu ditingkatkan dengan melakukan *tuning* model atau pengoptimalan model.

5.2.3. Training dan Pencarian Model SVM terbaik

Dalam rangka meningkatkan kinerja dari *support vector machine* terhadap data latih , maka perlu memilih parameter terbaik untuk model. Sebelumnya perlu menentukan tipe kernel terlebih dahulu , kemudian melakukan pencarian parameter terbaik yang dapat ditentukan dengan *tuning* model SVM pada R. Ada beberapa metode lain dalam optimasi parameter tetapi disini digunakan metode *Grid Search Optimization(GSO)* karena metode ini mudah untuk diimplementasikan dan sudah terdapat pada aplikasi R. Cara untuk melakukannya adalah dengan *grid search* dimana akan melatih banyak model untuk setiap pasangan yang berbeda dari

nilai ϵ , C dan γ dengan memilih yang terbaik. Kode programnya dapat dituliskan seperti pada skrip 5.6.

```
#perform a grid search
> tuneResult <- tune(svm, Y ~ X, data =
data, kernel="radial", ranges = list(epsilon =
seq(0,1,0.1), cost = 2^(-5:15), gamma = 2^(-
15:3)))
```

Skrip 5.6 Optimasi Grid Search

Pada penelitian ini menggunakan kernel *radial basis function* yang telah dijelaskan sebelumnya pada bab metodologi. Setelah itu sistem akan melatih model dengan $\epsilon = 0, 0.1, 0.2, \dots, 1$ dan $\text{cost} = 2^{-5}, 2^{-4}, 2^{-3}, \dots, 2^{15}$ serta $\gamma = 2^{-15}, 2^{-14}, 2^{-13}, \dots, 2^3$ yang berarti akan melatih beberapa pasangan model dimana cukup memerlukan waktu yang lama untuk melihat hasilnya. *Ranges* parameter tersebut ditentukan berdasarkan yang digunakan dalam penelitian secara umum [36].

Jika pelatihan model telah selesai, maka dapat dilihat berapa nilai parameter SVM yang menunjukkan kinerja terbaiknya berdasarkan data tersebut. Cara untuk melihatnya dapat dituliskan kode program seperti pada skrip 5.7.

```
> print(tuneResult)
```

Skrip 5.7 Kode Melihat Hasil Parameter

Hasil parameter terbaik pada model dapat dilihat pada gambar 5.4. Dari hasil tersebut tertulis bahwa sistem juga mengimplementasikan *k-fold cross validation* yang ditempatkan dalam proses *grid search optimization*. *Cross validation* merupakan metode perhitungan statistik yang diterapkan untuk membagi *training set* sebanyak jumlah yang ditentukan dengan nilai yang sama , sedangkan lainnya untuk model validasi. Pada

kasus ini, sistem menggunakan 10 *training set* yang merupakan standar dari penelitian [12].

```
Parameter tuning of 'svm':
- sampling method: 10-fold cross validation
- best parameters:
  epsilon cost gamma
    0.1    32      8
- best performance: 0.00431486
```

Gambar 5.4 Hasil Parameter Terbaik

Setelah itu, menuliskan kode program seperti pada skrip 5.8 untuk membuat nilai prediksi dari model yang telah dilakukan *tuning grid-search*.

```
> tunedModel <- tuneResult$best.model
> tunedModelY <- predict(tunedModel, data)
```

Skrip 5.8 Kode Membuat nilai Prediksi


Jika ingin melihat hasil nilai prediksi dalam bentuk plot maka dapat ditampilkan dengan menuliskan kode program seperti pada skrip 5.9 yang diatur dengan warna hijau.

```
> points(data$X, tunedModelY, col = "green",
  pch=4)
```

Skrip 5.9 Plot nilai Prediksi

Hasil dari nilai prediksi data dalam plot dapat dilihat pada gambar 5.5 yang ditunjukkan dengan titik warna hijau, dimana sumbu X

menunjukkan waktu dan sumbu Y menunjukkan jumlah wisatawan mancanegara.



Gambar 5.5 Hasil Plot nilai Prediksi

Selanjutnya adalah melihat hasil dari nilai prediksi dalam bentuk angka yang nantinya juga akan digunakan untuk menghitung akurasi peramalan. Cara untuk melihat angka hasil nilai prediksi dapat dituliskan dengan kode program seperti pada skrip 5.10.

```
> print(tunedModel$Y)
```


Skrip 5.10 Kode Melihat angka hasil prediksi

Hasil dari nilai prediksi ditunjukkan seperti gambar 5.6 dimana terdapat 76 data untuk data latih.

1	2	3	4	5	6	7	8
11.91822	11.93228	11.96180	12.00432	12.05413	12.10294	12.14145	12.16175
9	10	11	12	13	14	15	16
12.15971	12.13676	12.10019	12.06178	12.03486	12.03073	12.05521	12.10663
17	18	19	20	21	22	23	24
12.17585	12.24836	12.30808	12.34170	12.34238	12.31179	12.25978	12.20181
25	26	27	28	29	30	31	32
12.15480	12.13249	12.14173	12.18059	12.23904	12.30185	12.35298	12.38015
33	34	35	36	37	38	39	40
12.37820	12.35037	12.30712	12.26288	12.23187	12.22410	12.24283	12.28403
41	42	43	44	45	46	47	48
12.33790	12.39174	12.43346	12.45457	12.45195	12.42826	12.39081	12.34956
49	50	51	52	53	54	55	56
12.31461	12.29395	12.29174	12.30760	12.33689	12.37193	12.40399	12.42544
57	58	59	60	61	62	63	64
12.43177	12.42282	12.40293	12.38000	12.36345	12.36170	12.37981	12.41785
65	66	67	68	69	70	71	72
12.47067	12.52899	12.58178	12.61916	12.63503	12.62862	12.60463	12.57170
73	74	75	76				
12.53998	12.51831	12.51203	12.52186				

Gambar 5.6 Hasil nilai prediksi

Kemudian dari hasil tersebut disalin ke Microsoft excel untuk melihat akurasi dari model serta grafik plot dari data aktual dengan data prediksi. Pada pintu masuk yang datanya dilakukan transformasi, maka perlu dikembalikan ke bentuk semula terlebih dahulu dengan fungsi excel =EXP() yang merupakan kebalikan dari ln. Hasil dari perhitungan di Microsoft excel dapat dilihat seperti pada gambar 5.7.



Gambar 5.7 Hasil perhitungan Microsoft Excel

Setelah itu model SVM tersebut juga diimplementasikan pada data uji. Dimana proses *testing* dilakukan guna untuk percobaan

terhadap model terbaik yang nantinya akan dilakukan untuk peramalan pada periode kedepan.

Cara untuk implementasi pada data uji sama seperti langkah-langkah yang dilakukan sebelumnya. Hal pertama yang dilakukan yaitu dengan memanggil data uji yang sudah disiapkan dalam bentuk csv. Kode program yang dituliskan terlihat seperti pada skrip 5.11.

```
> dataDirectory <- "D:/ta/Data/Data per pintu
masuk/Ngurah Rai/"

> data <- read.csv(paste(dataDirectory,
'Ngurah Rai Test Transform.csv', sep=""),
header = TRUE)
```

Skip 5.11 Kode untuk memanggil data uji

Langkah selanjutnya sama seperti yang dilakukan pada data latih , hanya terdapat sedikit perbedaan. Jika pada data latih dilakukan *grid search* untuk mendapatkan model SVM terbaik, maka pada data uji tidak perlu dilakukan kembali. Pada data uji hanya perlu memasukkan model SVM terbaik beserta parameternya dari hasil yang telah didapatkan. Kode program yang dituliskan terlihat seperti pada skrip 5.12.

```
> model <- svm(Y ~ X, data = data , kernel=
"radial" , epsilon = 0.1 , cost = 32 , gamma =
8)
```

Skip 5.12 Implementasi model terbaik pada data uji

Setelah mendapatkan hasil prediksinya maka untuk menghitung akurasi sama seperti langkah sebelumnya. Kemudian juga dilakukan uji tes DCA untuk data latih dan data uji. Tes DCA dilakukan dengan melihat berapa tanda perubahan arah yang sama antara data prediksi dengan aktual kemudian dibagi dengan total tanda tersebut.

5.3. Peramalan pada periode kedepan

Pada tahap ini masuk pada tujuan utama penelitian yaitu meramalkan jumlah wisatawan mancanegara di Indonesia pada periode kedepan. Pada penelitian ini akan meramalkan jumlah wisatawan untuk satu periode kedepan atau 12 bulan di tahun 2017.

Langkah pertama untuk memprediksi nilai berikutnya pada program R yaitu *load library e1071* terlebih dahulu untuk memanggil fungsi SVM seperti pada skrip 5.13.

```
#Load Library
> library(e1071)
```

Skrip 5.13 Kode memanggil fungsi SVM

Selanjutnya inisiasi variabel x dan y dimana x menunjukkan waktu dan y menunjukkan jumlah wisman. Kode programnya dapat dituliskan seperti pada skrip 5.14 . Dalam hal ini jumlah wisman di-*input* secara manual dari data uji.

```
> x <- c(1:32)

> y <- c(12.56, 12.71, 12.79, 12.73, 12.77,
12.73, 12.59, 12.74, 12.57, 12.72, 12.59,
12.64, 12.57, 12.79, 12.85, 12.61, 12.85,
12.81, 12.48, 12.8, 12.75, 12.81, 12.78, 12.81,
12.89, 12.91, 13.09, 12.99, 13, 12.96, 12.89,
13)
```

Skrip 5.14 Input data uji

Kemudian menempatkan variabel tersebut dalam suatu frame yang nantinya akan diakses pada saat dilakukan peramalan. Selain itu juga menentukan rentang nilai yang akan diramalkan. Pada penelitian ini meramalkan jumlah wisman untuk satu tahun kedepan sehingga akan ditentukan berapakah *value* pada 12 data berikutnya. Kode program dapat dituliskan seperti pada skrip 5.15 dimana *c(33:44)* merupakan nilai peramalan selama 12 bulan.

```
> DF <- data.frame(x = x, y = y)
> nextvalues <- c(33:44)
```

Skrip 5.15 Kode Membuat Data Frame

Setelah itu memasuki tahap terakhir peramalan yaitu memasukkan model SVM terbaik beserta parameter yang didapatkan sebelumnya pada proses pelatihan. Dan selanjutnya dilakukan prediksi nilai berikutnya . Kode program dapat dituliskan seperti pada gambar 5.16.

```
> model <- svm(y ~ x, kernel = "radial", epsilon
= 0.1, gamma = 8, cost = 32)
> predict (model , newdata = data.frame(x =
nextvalues))
```

Skrip 5.16 Kode untuk memprediksi nilai berikutnya

Nilai peramalan selama 12 bulan kedepan dapat dilihat pada gambar 5.8.

1	2	3	4	5	6	7	8
13.06467	13.10265	13.06430	12.97682	12.88990	12.83196	12.80328	12.79229
9	10	11	12				
12.78894	12.78813	12.78797	12.78794				

Gambar 5.8 Hasil nilai peramalan 12 bulan kedepan

Nilai tersebut kemudian diubah menjadi bentuk semula dengan fungsi =EXP() yang dapat dilakukan pada Microsoft Excel. Hasil yang diperoleh dapat dilihat pada tabel 5.5.

A	B	C
Jan-17	13.06467	471970
Feb-17	13.10265	490240
Mar-17	13.0643	471795
Apr-17	12.97682	432276
May-17	12.8899	396289
Jun-17	12.83196	373981
Jul-17	12.80328	363407
Aug-17	12.79229	359435
Sep-17	12.78894	358233
Oct-17	12.78813	357943
Nov-17	12.78797	357886
Dec-17	12.78794	357875

Table 5.5 Perubahan nilai transformasi ke bentuk awal

BAB VI

HASIL DAN PEMBAHASAN

Pada bab ini dijelaskan mengenai proses uji coba yang dilakukan dalam penelitian untuk mengetahui keakuratan model dari metode yang digunakan. Di dalam bab ini dijelaskan pula analisis hasil yang diperoleh dari proses implementasi yang telah dibahas pada bab 5.

6.1. Hasil Implementasi Model

Dalam tugas akhir ini, uji coba pada model diimplementasikan dengan menggunakan aplikasi R. Dalam penelitian ini melibatkan dua variabel yaitu variabel X sebagai periode waktu dalam bulan dan variabel Y sebagai jumlah wisatawan. Model terbaik dari SVM ditentukan berdasarkan parameter-parameter yang dibutuhkan disesuaikan dengan tipe kernel yang digunakan yakni RBF. Selain itu, model terbaik juga ditentukan dengan algoritma *grid-search* yang telah tersedia di aplikasi R. Kegunaan algoritma tersebut akan melakukan iterasi hingga mendapatkan model terbaik dari tiap pasangan parameter yang telah ditentukan. Pada sub bab ini akan dijelaskan secara rinci hasil dari peramalan jumlah wisatawan dari 6 pintu masuk yang dilakukan . Hasil tersebut melibatkan parameter model terbaik dari tiap pintu masuk serta nilai peramalan yang diilustrasikan dalam bentuk grafik plot. Kemudian juga dilakukan perhitungan mengenai kemampuan mengikuti pola data atau *directional change accuracy (DCA)* dari tiap pintu masuk. Tes DCA diperlukan untuk mengukur akurasi perubahan arah model antara data aktual dan data peramalan . Berikut adalah hasil implementasi untuk setiap pintu masuk.

6.1.1. Pintu Masuk Ngurah Rai

Model pertama adalah model pada pintu masuk Ngurah Rai. Pada tabel 6.1 dapat dilihat nilai parameter model SVM terbaik yang didapatkan dari proses *training*. Pelatihan model secara keseluruhan dari berbagai parameter dapat dilihat pada lampiran D.

Table 6.1 Parameter Optimal pada dataset Ngurah Rai

Parameter Optimal	
Kernel	<i>Radial Basis Function</i>
Parameter	3 parameter
C	32
Gamma	8
Epsilon	0.1

Dari hasil optimasi parameter yang dilakukan dengan menggunakan *grid-search* ditemukan parameter paling optimal dengan nilai *Cost* sebesar 32, *gamma* sebesar 8 dan *epsilon* sebesar 0.1. Untuk tabel akurasi dari model dapat dilihat pada tabel 6.2.

Table 6.2 Uji Performa Model pada dataset Ngurah Rai


Uji Performa Model	
MAPE Training	3.90%
MAPE Testing	5.10%
MSE Training	139497869.3
MSE Testing	703326805.7

Sedangkan untuk hasil kemampuan mengikuti pola data yang dihitung menggunakan *Microsoft excel* dapat dilihat pada tabel 6.3.

Table 6.3 Tes DCA pada dataset Ngurah Rai

Tes DCA	
Data Training	66.67%
Data Testing	58.06%

Diketahui hasil dari uji kinerja model bahwa *mean absolute percentage error* pada data *training* lebih kecil dari data *testing*. Pada data *training* diperoleh sebesar 3.90% sedangkan data *testing* yaitu sebesar 5.10% . Berdasarkan hasil kemampuan mengikuti pola data, data *training* juga lebih baik daripada data *testing*. Kemudian setelah menghitung akurasi dari model maka melakukan *plotting* grafik antara data aktual dengan data prediksi dari data uji/*testing*. Hasil *plotting* grafik dapat dilihat pada gambar 6.1. Pada gambar tersebut juga terlihat nilai peramalan untuk periode kedepan selama 12 bulan atau setara dengan satu tahun. Hasil peramalan secara detail dapat dilihat pada lampiran F.



Gambar 6.1 Grafik perbandingan data uji Ngurah Rai dan hasil peramalan

6.1.2. Pintu Masuk Batam

Model kedua adalah model pada pintu masuk Batam. Pada tabel 6.4 dapat dilihat nilai parameter model SVM terbaik yang didapatkan dari proses *training*. Pelatihan model secara keseluruhan dari berbagai parameter dapat dilihat pada lampiran D.

Table 6.4 Parameter Optimal pada dataset Batam

Parameter Optimal	
Kernel	<i>Radial Basis Function</i>
Parameter	3 parameter
C	128
Gamma	8
Epsilon	0.3

Dari hasil optimasi parameter yang dilakukan dengan menggunakan *grid-search* ditemukan parameter paling optimal dengan nilai *Cost* sebesar 128, *gamma* sebesar 8 dan *epsilon* sebesar 0.3. Untuk tabel akurasi dari model dapat dilihat pada tabel 6.5.

Table 6.5 Uji Performa Model pada dataset Batam


Uji Performa Model	
MAPE Training	8.59%
MAPE Testing	5.71%
MSE Training	131303726.6
MSE Testing	197101706.3

Sedangkan untuk hasil kemampuan mengikuti pola data yang dihitung menggunakan *Microsoft excel* dapat dilihat pada tabel 6.6.

Table 6.6 Tes DCA pada dataset Batam

Tes DCA	
Data Training	54.67%
Data Testing	70.97%

Diketahui hasil dari uji kinerja model bahwa *mean absolute percentage error* pada data *testing* lebih kecil dari data *training*. Pada data *testing* diperoleh sebesar 5.71% sedangkan data *training* yaitu sebesar 8.59% . Berdasarkan hasil kemampuan mengikuti pola data, data *testing* juga lebih baik daripada data *training*. Kemudian setelah menghitung akurasi dari model maka melakukan *plotting* grafik antara data aktual dengan data prediksi dari data uji/ *testing*. Hasil *plotting* grafik dapat dilihat pada gambar 6.2. Pada gambar tersebut juga terlihat nilai peramalan untuk periode kedepan selama 12 bulan atau setara dengan satu tahun. Hasil peramalan secara detail dapat dilihat pada lampiran F.



Gambar 6.2 Grafik perbandingan data uji Batam dan hasil peramalan

6.1.3. Pintu Masuk Tanjung Uban

Model ketiga adalah model pada pintu masuk Tanjung Uban. Pada tabel 6.7 dapat dilihat nilai parameter model SVM terbaik yang didapatkan dari proses *training*. Pelatihan model secara keseluruhan dari berbagai parameter dapat dilihat pada lampiran D.

Table 6.7 Parameter Optimal pada dataset Tanjung Uban

Parameter Optimal	
Kernel	<i>Radial Basis Function</i>
Parameter	3 parameter
C	512
Gamma	4
Epsilon	1

Dari hasil optimasi parameter yang dilakukan dengan menggunakan *grid-search* ditemukan parameter paling optimal dengan nilai *Cost* sebesar 512 , *gamma* sebesar 4 dan *epsilon* sebesar 1 . Untuk tabel akurasi dari model dapat dilihat pada tabel 6.8.

Table 6.8 Uji Performa Model pada dataset Tanjung Uban


Uji Performa Model	
MAPE Training	9.37%
MAPE Testing	11.90%
MSE Training	9817217
MSE Testing	11404919

Sedangkan untuk hasil kemampuan mengikuti pola data yang dihitung menggunakan *Microsoft excel* dapat dilihat pada tabel 6.9.

Table 6.9 Tes DCA pada dataset Tanjung Uban

Tes DCA	
Data Training	56.06%
Data Testing	71.43%

Diketahui hasil dari uji kinerja model bahwa *mean absolute percentage error* pada data *training* lebih kecil dari data *testing*. Pada data *training* diperoleh sebesar 9.37% sedangkan data *testing* yaitu sebesar 11.90% . Berdasarkan hasil kemampuan mengikuti pola data, data *testing* lebih baik daripada data *training*. Kemudian setelah menghitung akurasi dari model maka melakukan *plotting* grafik antara data aktual dengan data prediksi dari data uji/*testing*. Hasil *plotting* grafik dapat dilihat pada gambar 6.3. Pada gambar tersebut juga terlihat nilai peramalan untuk periode kedepan selama 12 bulan atau setara dengan satu tahun. Hasil peramalan secara detail dapat dilihat pada lampiran F.



Gambar 6.3 Grafik perbandingan data uji Tanjung Uban dan hasil peramalan

6.1.4. Pintu Masuk Husein Sastranegara

Model keempat adalah model pada pintu masuk Husein Sastranegara. Pada tabel 6.10 dapat dilihat nilai parameter model SVM terbaik yang didapatkan dari proses *training*. Pelatihan

model secara keseluruhan dari berbagai parameter dapat dilihat pada lampiran D.

Table 6.10 Parameter Optimal pada dataset Husein Sastranegara

Parameter Optimal	
Kernel	<i>Radial Basis Function</i>
Parameter	3 parameter
C	128
Gamma	4
Epsilon	0.8

Dari hasil optimasi parameter yang dilakukan dengan menggunakan *grid-search* ditemukan parameter paling optimal dengan nilai *Cost* sebesar 128 , *gamma* sebesar 4 dan *epsilon* sebesar 0.8 . Untuk tabel akurasi dari model dapat dilihat pada tabel 6.11.

Table 6.11 Uji Performa Model pada dataset Husein Sastranegara


Uji Performa Model	
MAPE Training	21.50%
MAPE Testing	19.81%
MSE Training	6602414
MSE Testing	9013283

Sedangkan untuk hasil kemampuan mengikuti pola data yang dihitung menggunakan *Microsoft excel* dapat dilihat pada tabel 6.12.

Table 6.12 Tes DCA pada dataset Husein Sastranegara

Tes DCA	
Data Training	53.03%
Data Testing	75.00%

Diketahui hasil dari uji kinerja model bahwa *mean absolute percentage error* pada data *testing* lebih kecil dari data *training*. Pada data *testing* diperoleh sebesar 19.81% sedangkan data *training* yaitu sebesar 21.50% . Berdasarkan hasil kemampuan mengikuti pola data, data *testing* juga lebih baik daripada data *training*. Kemudian setelah menghitung akurasi dari model maka melakukan *plotting* grafik antara data aktual dengan data prediksi dari data uji/*testing*. Hasil *plotting* grafik dapat dilihat pada gambar 6.4. Pada gambar tersebut juga terlihat nilai peramalan untuk periode kedepan selama 12 bulan atau setara dengan satu tahun. Hasil peramalan secara detail dapat dilihat pada lampiran F.



Gambar 6.4 Grafik perbandingan data uji Husein Sastranegara dan hasil peramalan

6.1.5. Pintu Masuk Tanjung Pinang

Model kelima adalah model pada pintu masuk Tanjung Pinang. Pada tabel 6.13 dapat dilihat nilai parameter model SVM terbaik yang didapatkan dari proses *training*. Pelatihan model secara keseluruhan dari berbagai parameter dapat dilihat pada lampiran D.

Table 6.13 Parameter Optimal pada dataset Tanjung Pinang

Parameter Optimal	
Kernel	<i>Radial Basis Function</i>
Parameter	3 parameter
C	512
Gamma	4
Epsilon	0.1

Dari hasil optimasi parameter yang dilakukan dengan menggunakan *grid-search* ditemukan parameter paling optimal dengan nilai *Cost* sebesar 512 , *gamma* sebesar 4 dan *epsilon* sebesar 0.1 . Untuk tabel akurasi dari model dapat dilihat pada tabel 6.14 .

Table 6.14 Uji Performa Model pada dataset Tanjung Pinang


Uji Performa Model	
MAPE Training	10.88%
MAPE Testing	8.23%
MSE Training	1885812
MSE Testing	1115331

Sedangkan untuk hasil kemampuan mengikuti pola data yang dihitung menggunakan *Microsoft excel* dapat dilihat pada tabel 6.15.

Table 6.15 Tes DCA pada dataset Tanjung Pinang

Tes DCA	
Data Training	52.00%
Data Testing	70.97%

Diketahui hasil dari uji kinerja model bahwa *mean absolute percentage error* pada data *testing* lebih kecil dari data *training*. Pada data *testing* diperoleh sebesar 8.23% sedangkan data *training* yaitu sebesar 10.88% . Berdasarkan hasil kemampuan mengikuti pola data, data *testing* juga lebih baik daripada data *training*. Kemudian setelah menghitung akurasi dari model maka melakukan *plotting* grafik antara data aktual dengan data prediksi dari data uji/ *testing*. Hasil *plotting* grafik dapat dilihat pada gambar 6.5. Pada gambar tersebut juga terlihat nilai peramalan untuk periode kedepan selama 12 bulan atau setara dengan satu tahun. Hasil peramalan secara detail dapat dilihat pada lampiran F.



Gambar 6.5 Grafik perbandingan data uji Tanjung Pinang dan hasil peramalan

6.1.6. Pintu Masuk Sepinggaan

Model keenam adalah model pada pintu masuk Sepinggaan. Pada tabel 6.16 dapat dilihat nilai parameter model SVM terbaik yang didapatkan dari proses *training*. Pelatihan model secara keseluruhan dari berbagai parameter dapat dilihat pada lampiran D.

Table 6.16 Parameter Optimal pada dataset Sepinggaan

Parameter Optimal	
Kernel	<i>Radial Basis Function</i>
Parameter	3 parameter
C	32
Gamma	8
Epsilon	0

Dari hasil optimasi parameter yang dilakukan dengan menggunakan *grid-search* ditemukan parameter paling optimal dengan nilai *Cost* sebesar 32 , *gamma* sebesar 8 dan *epsilon* sebesar 0 . Untuk tabel akurasi dari model dapat dilihat pada tabel 6.17.

Table 6.17 Uji Performa Model pada dataset Sepinggaan


Uji Performa Model	
MAPE Training	8.91%
MAPE Testing	10.04%
MSE Training	24347.15
MSE Testing	26218.697

Sedangkan untuk hasil kemampuan mengikuti pola data yang dihitung menggunakan *Microsoft excel* dapat dilihat pada tabel 6.18.

Table 6.18 Tes DCA pada dataset Sepinggan

Tes DCA	
Data Training	52.00%
Data Testing	70.97%

Diketahui hasil dari uji kinerja model bahwa *mean absolute percentage error* pada data *training* lebih kecil dari data *testing*. Pada data *training* diperoleh sebesar 8.91% sedangkan data *testing* yaitu sebesar 10.04% . Berdasarkan hasil kemampuan mengikuti pola data, data *testing* lebih baik daripada data *training*. Kemudian setelah menghitung akurasi dari model maka melakukan *plotting* grafik antara data aktual dengan data prediksi dari data uji/*testing*. Hasil *plotting* grafik dapat dilihat pada gambar 6.6. Pada gambar tersebut juga terlihat nilai peramalan untuk periode kedepan selama 12 bulan atau setara dengan satu tahun. Hasil peramalan secara detail dapat dilihat pada lampiran F.



Gambar 6.6 Grafik perbandingan data uji Sepinggan dan hasil peramalan

6.2. Analisis Keseluruhan Hasil Uji Coba

Pada tahap ini merupakan proses untuk menganalisis dari semua hasil percobaan yang telah dilakukan sebelumnya . Adapun hasil dari setiap model akan dibandingkan manakah yang terbaik dari tiap pola data yang ada. Sebelum menganalisis hasil lebih lanjut dapat dilihat terlebih dahulu pola data yang ada dari tiap pintu masuk. Tabel 6.19 menunjukkan pola data dari tiap pintu masuk yang ada.

Table 6.19 Pola data per pintu masuk

Dataset	Pola Data
Ngurah Rai	<i>Trend Seasonal</i>
Batam	<i>Seasonal</i>
Tanjung Uban	<i>Horizontal</i>
Husein Sastranegara	<i>Irregular</i>
Tanjung Pinang	<i>Horizontal</i>
Sepinggan	<i>Irregular</i>

Selain itu, ditampilkan pula hasil nilai parameter optimal serta MAPE yang dihasilkan dari keenam uji coba model pada tabel 6.20.

Table 6.20 Parameter Optimal pada setiap pintu masuk

Dataset	C	Gamma	Epsilon	MAPE Train	MAPE Test
Ngurah Rai	32	8	0.1	3.90%	5.10%
Batam	128	8	0.3	8.59%	5.71%
Tanjung Uban	512	4	1	9.37%	11.90%
Husein Sastranegara	128	4	0.8	21.50%	19.81%

Dataset	C	Gamma	Epsilon	MAPE Train	MAPE Test
Tanjung Pinang	512	4	0.1	10.88%	8.23%
Sepinggan	32	8	0	8.91%	10.04%

Berdasarkan tabel 6.19 dan tabel 6.20 dapat diketahui bahwa:

- Pada tiap dataset pintu masuk memiliki pola data yang berbeda.
- Peramalan pada masing-masing dataset memiliki parameter optimal dan tingkat akurasi yang berbeda-beda.
- Dengan metode SVM, pola data yang ada dari tiap pintu masuk dapat mempengaruhi MAPE yang dihasilkan. Dimana pada pola *tren seasonal* memiliki akurasi yang paling tinggi dari pola yang lainnya dengan MAPE berkisar 3-5% pada dataset Ngurah Rai. Pola data yang baik berikutnya yaitu Batam dengan pola *Seasonal* dimana MAPE berkisar 5-9% . Sedangkan untuk pola data lainnya memiliki nilai yang cukup baik dengan MAPE berkisar 8-20%.
- Parameter optimal yang diperoleh dari tiap pintu masuk berbeda karena menyesuaikan pada pola data yang ada. Dimana besar kecilnya nilai parameter yang diperoleh tidak menjamin MAPE yang dihasilkan.
- Pada setiap dataset memiliki akurasi yang berbeda-beda dimana ada yang tergolong sangat baik, baik dan layak/cukup.

Dari hasil akurasi peramalan dapat dikelompokkan dengan mengikuti aturan pada tabel 2.6. Hasil pengelompokan tersebut dapat dilihat pada tabel 6.21.

Table 6.21 Hasil Pengelompokan Peramalan

Dataset	Rata-Rata MAPE	Keterangan	Hasil Peramalan
Ngurah Rai	4.50%	<10%	Sangat Baik
Batam	7.15%	<10%	Sangat Baik
Tanjung Uban	10.63%	10-20%	Baik
Husein Sastranegara	20.65%	20-50%	Layak/Cukup
Tanjung Pinang	9.55%	<10%	Sangat Baik
Sepinggan	9.47%	<10%	Sangat Baik

Dari tabel 6.21 dapat dilihat bahwa rata-rata hasil peramalan menunjukkan akurasi yang sangat baik/baik. Hanya satu pintu masuk yang menunjukkan akurasi peramalan yang tergolong layak/cukup yaitu Husein Sastranegara.

Pada sub bab 4.3.1 juga menjelaskan bahwa data yang dinormalisasi dapat menghasilkan performa yang lebih baik. Tabel 6.22 menunjukkan hasil perbandingan akurasi dari data yang dilakukan transformasi dan tanpa transformasi. Tabel tersebut hanya menampilkan perbandingan pada pintu masuk yang tidak memenuhi asumsi normalitas saja.

Table 6.22 Perbandingan akurasi pada data transformasi dan tanpa transformasi

Dataset	Rata-Rata MAPE (Transformasi)	Rata-Rata MAPE (Tanpa Transformasi)
Ngurah Rai	4.50%	4.48%
Tanjung Uban	10.63%	10.99%
Tanjung Pinang	9.55%	9.59%

Berdasarkan tabel 6.22 dapat diketahui bahwa:

- a. Data yang telah dilakukan transformasi tidak selalu memiliki akurasi yang lebih baik dari yang tanpa dilakukan transformasi. Hal ini dapat terlihat pada dataset Ngurah Rai untuk data tanpa transformasi memiliki nilai MAPE lebih kecil 2% dari data yang telah di-transformasi.
- b. Nilai MAPE pada data yang dilakukan transformasi dan tanpa transformasi memiliki selisih yang tidak begitu besar. Dapat dilihat pada penelitian ini selisih yang diperoleh hanya sekitar 0.02% - 0.36%.

Berikutnya yaitu menganalisis hasil dari tes DCA yang digunakan untuk melihat apakah model peramalan mampu meramalkan perubahan arah data. Hasil tes DCA yang telah dilakukan pada penelitian dapat dilihat pada tabel 6.23.

Table 6.23 Hasil tes DCA per pintu masuk

Dataset	DCA Train	DCA Test	Rata-Rata DCA
Ngurah Rai	66.67%	58.06%	62.36%
Batam	54.67%	70.97%	62.82%
Tanjung Uban	56.06%	71.43%	63.74%
Husein Sastranegara	53.03%	75.00%	64.01%
Tanjung Pinang	52.00%	70.97%	61.48%
Sepinggan	52.00%	70.97%	61.48%

Berdasarkan tabel 6.23 dapat diketahui bahwa:

- a. Nilai DCA pada masing-masing dataset berbeda.
- b. Secara keseluruhan nilai DCA untuk setiap dataset pintu masuk cukup baik yakni lebih dari 60%.

- c. SVM mampu meramalkan perubahan arah data dengan tingkat akurasi yang cukup tinggi.
- d. Nilai MAPE yang rendah belum tentu menghasilkan nilai DCA yang tinggi begitupun sebaliknya. Hal tersebut dapat terlihat bahwa MAPE terendah ada pada dataset Ngurah Rai tetapi hasil DCA yang diperoleh lebih rendah dari dataset Husein Sastranegara. Sedangkan pada dataset Husein Sastranegara dengan MAPE tertinggi memiliki DCA yang paling tinggi dari dataset lainnya sebesar 64.01%.

Setelah itu dilakukan analisis juga dari tiap kluster berdasarkan nilai MAPE dan DCA yang telah diperoleh. Tabel 6.24 menunjukkan perbandingan MAPE dan DCA dari tiap kluster.

Table 6.24 Tabel perbandingan MAPE dan DCA tiap kluster

Dataset	Kluster	Wisatawan	MAPE	DCA
Ngurah Rai	Tinggi	Tertinggi	4.50%	62.36%
Batam	Tinggi	Terendah	7.15%	62.82%
Tanjung Uban	Sedang	Tertinggi	10.63%	63.74%
Husein Sastranegara	Sedang	Terendah	20.65%	64.01%
Tanjung Pinang	Rendah	Tertinggi	9.55%	61.48%
Sepinggan	Rendah	Terendah	9.47%	61.48%

Berdasarkan tabel 6.24 dapat diketahui bahwa:

- a. Pada kluster 'tinggi' memiliki nilai MAPE yang lebih kecil dari kluster lainnya. Dengan nilai 4.50% untuk nilai wisatawan tertinggi dan 7.15% untuk nilai wisatawan terendah di kluster tersebut.
- b. Pada kluster 'sedang' memiliki nilai akurasi DCA yang lebih tinggi dari kluster lainnya. Dapat dilihat bahwa

nilai wisatawan terendah di klaster tersebut memiliki DCA sebesar 64.01% sedangkan untuk nilai tertinggi sebesar 63.74%. Tetapi klaster ini memiliki nilai MAPE yang paling besar dari klaster lainnya.

- c. Pada klaster 'rendah' memiliki nilai akurasi DCA paling rendah dari klaster lain, dengan nilai yang sama untuk nilai wisatawan tertinggi dan terendah yakni sebesar 61.48%.

(Halaman ini sengaja dikosongkan)

BAB VII

KESIMPULAN DAN SARAN

Pada bagian ini berisi kesimpulan dari semua proses yang telah dilakukan dalam tugas akhir serta saran yang dapat diberikan untuk pengembangan kedepannya yang lebih baik.

7.1. Kesimpulan

Berdasarkan uji coba yang telah dilakukan dalam tugas akhir ini, maka kesimpulan yang dapat diambil adalah :

1. Metode *Support Vector Machine* dapat digunakan sebagai pilihan dalam meramalkan jumlah wisatawan mancanegara di Indonesia dari berbagai pintu masuk karena memiliki nilai MAPE yang tergolong baik. Akan tetapi pada penelitian ini hanya diuji coba pada satu data set untuk masing-masing pola data yang bisa jadi hal ini tidak konsisten jika diuji coba pada banyak dataset.
2. Hasil peramalan yang tidak tentu pada jumlah wisatawan mancanegara di enam pintu masuk, dapat memberikan informasi bagi pihak industri pariwisata terkait untuk merencanakan strategi yang tepat apabila terjadi penurunan jumlah wisatawan pada periode tertentu.
3. Dalam penerapan implementasi *Support Vector Machine* pada peramalan jumlah wisatawan mancanegara di Indonesia dapat dilakukan proses optimasi dengan menggunakan *grid search*. *Grid Search* digunakan untuk mencari solusi model terbaik dari berbagai pasangan model yang ada berdasarkan parameter tertentu. Dikarenakan jika melakukan percobaan satu persatu akan memakan banyak waktu dan model yang diperoleh belum tentu yang terbaik.
4. Uji normalitas diperlukan untuk melihat apakah data telah berdistribusi normal atau tidak. Apabila data belum berdistribusi normal, maka perlu ditransformasikan

terlebih dahulu sebelum diimplementasikan pada model SVM untuk memperoleh hasil yang lebih baik.

5. Peramalan dengan menggunakan SVM dapat bergantung pada pola data yang ada. Hal tersebut dapat dilihat pada MAPE yang dihasilkan dari tiap pola data pintu masuk memiliki nilai berbeda. Dimana pada penelitian ini SVM paling cocok digunakan untuk pola *trend seasonal* jika dilihat berdasarkan MAPE terendah yakni 4.50%.
6. Nilai MAPE yang rendah belum tentu menghasilkan nilai DCA yang tinggi begitupun sebaliknya. Hasil DCA tertinggi pada penelitian ini diperoleh pada pintu masuk Husein Sastranegara dengan akurasi 64.01% yang mana memiliki MAPE tertinggi.

7.2. Saran

Saran yang dapat diberikan berdasarkan proses uji coba, penarikan kesimpulan, dan batasan masalah dari tugas akhir ini adalah :

1. Penelitian ini menggunakan metode SVM untuk peramalan wisatawan mancanegara pada 6 pintu masuk di Indonesia diharapkan dikemudian hari ada yang mencoba melakukan dengan metode lain dan berbagai pintu masuk lainnya. Hal tersebut digunakan untuk membandingkan akurasi peramalan dari tiap metode untuk melihat metode apa yang paling cocok digunakan dalam meramalkan wisatawan mancanegara di Indonesia.
2. Penentuan pola data dilakukan dengan melihat secara visual berdasarkan teori yang ada. Diharapkan untuk kedepannya dapat menentukan pola data dengan disertai perhitungan untuk lebih membuktikan bahwa pola data tersebut memang benar.
3. Diharapkan untuk kedepannya dapat menguji coba pada banyak dataset agar lebih meyakinkan bahwa metode SVM paling cocok pada pola data *tren seasonal*.

4. Penggunaan optimasi seperti *grid search* sangat membantu untuk memperoleh model terbaik dari suatu karakteristik data tertentu. Diharapkan dapat menggunakan metode optimasi lainnya sebagai alternatif pilihan.
5. Adanya penambahan variabel lain yang mempengaruhi jumlah wisatawan mancanegara di Indonesia untuk melihat faktor lain secara lebih luas.

(Halaman ini sengaja dikosongkan)

DAFTAR PUSTAKA

- [1] UNWTO, Sustainable Tourism for Development Guidebook. Madrid, Spain: World Tourism Organization, 2013.
- [2] L. S. Sebele, "Community-based tourism ventures, benefits and challenges: Khama Rhino Sanctuary Trust, Central District, Botswana," *Tourism Management*, vol. 31, p. 136=146, 2010.
- [3] Akarapong Untong, Mingsarn Kaosa-ard, Vicente Ramos, Korawan Sangkakorn, and Javier Rey-Maquieria, "Factors Influencing Local Resident Support for Tourism Development: A Structural Equation Model," in *The APTA Conference 2010, Macau*, 2010.
- [4] Lin, C. J., Chen, H. F., & Lee, T. S. (2011). Forecasting tourism demand using time series, artificial neural networks and multivariate adaptive regression splines: Evidence from Taiwan. *International Journal of Business Administration*, 2(2), 14.
- [5] Badan Koordinasi Penanaman Modal, "Investasi di Indonesia," BKPM, [Online]. Available: <http://www.bkpm.go.id/id/peluang-investasi/peluang-berdasarkan-sektor/pariwisata>. [Accessed 11 2 2017]
- [6] Ranking Devisa Pariwisata Terhadap Komoditas Ekspor Lainnya tahun 2004-2009. Kementerian Kebudayaan dan Pariwisata RI. Diakses pada 27 Juni 2011.
- [7] Indonesia Investments, "Industri Pariwisata Indonesia," 16 12 2016. [Online]. Available: <http://www.indonesia-investments.com/id/bisnis/industri-sektor/pariwisata/item6051?>. [Accessed 12 2 2017]

- [8] One World Nations Online, "Countries of The World by Area," 2010. [Online]. Available: http://www.nationsonline.org/oneworld/countries_by_area.htm . [Accessed 19 09 2016].
- [9] D. Gliemourinsie, "Jumlah Kedatangan Wisatawan Mancanegara ke RI Menyusut," SINDONews, 1 8 2016. [Online]. Available: <https://ekbis.sindonews.com/read/1127834/34/jumlah-kedatangan-wisatawan-mancanegara-ke-ri-menyusut-1470031946>. [Accessed 12 2 2017].
- [10] Lin, C. J., & Lee, T. S. (2013). Tourism Demand Forecasting: Econometric Model based on Multivariate Adaptive Regression Splines, Artificial Neural Network and Support Vector Regression. *Advances in Management and Applied Economics*, 3(6), 1.
- [11] Cristianini N., Taylor J.S., "An Introduction to Support Vector Machines and Other Kernel-Based Learning Methods", Cambridge Press University, 2000
- [12] Naufal, R.A. (2016). *Prediksi Jumlah Pendertia Demam Berdarah di Kabupaten Malang Menggunakan Grid Search-Support Vector Machine (SVM)*. Surabaya, ITS: Jurusan Sistem Informasi.
- [13] Samsudin, R., Saad, P., & Shabri, A. (2010). Hybridizing GMDH and least squares SVM support vector machine for forecasting tourism demand. *International Journal of Research and Reviews in Applied Sciences*, 3(3), 274-279.
- [14] Xu, X., Law, R., Chen, W., & Tang, L. (2016). Forecasting tourism demand by extracting fuzzy Takagi–Sugeno rules from trained SVMs. *CAAI Transactions on Intelligence Technology*, 1(1), 30-42.
- [15] UNWTO, "UNWTO Tourism Highlights 2016 Edition," 2016. [Online]. Available: <http://www.e->

- unwto.org/doi/pdf/10.18111/9789284418145. [Accessed 12 2 2017].
- [16] Nomor, U. U. R. I. (10). tahun 2009 tentang Kepariwisata. Undang-Undang Republik Indonesia Nomor, 10, 2007.
 - [17] Badan Pusat Statistik, "Konsep dan Definisi Statistik Kunjungan Wisatawan Mancanegara," BPS, [Online]. Available: <https://www.bps.go.id/Subjek/view/id/16>. [Accessed 12 2 2017].
 - [18] Frechtling, Douglas C. *Forecasting Tourism Demand: Methods and Strategies*. Edisi 1. Plant A tree. Oxpord. 2001
 - [19] Martiningtyas, N. 2004. Diktat Statistika. Surabaya : STIKOM Surabaya.
 - [20] Makridakis, Wheelwright and Mcgee. 1991. Metode dan Aplikasi Peramalan, Edisi Kedua. Jakarta: Erlangga.
 - [21] Kucharavy, D. De Guio, R. 2005; <http://www.transtutors.com> 2012
 - [22] Montgomery, Douglas C dkk. *Intoduction to Time Series Analysis and Forecasting*. United State of America. Wiley Interscience. 2008.
 - [23] Agusta, Y. 2007. K-means - Penerapan, Permasalahan dan Metode Terkait. Jurnal Sistem dan Informatika Vol. 3 (Februari 2007): 47-60
 - [24] Santosa, B. (2007). Data Mining Teknik Pemanfaatan Data untuk Keperluan Bisnis. *Yogyakarta: Graha Ilmu*, 978(979), 756
 - [25] Pakar, Y. D. (2003). Metode penelitian

- [26] Vapnik V.N., “The Nature of Statistical Learning Theory”, 2nd edition, Springer-Verlag, New York Berlin Heidelberg, 1999
- [27] Santoso, B., 2007, Data Mining Teknik Pemanfaatan Data untuk Keperluan Bisnis, Graha Ilmu, Yogyakarta.
- [28] Nugroho, A. S., Witarto, A. B., & Handoko, D. (2003). Support Vector Machine. Teori dan Aplikasinya dalam Bioinformatika, Ilmu Komputer. com, Indonesia.
- [29] Chiu, D. Y., & Chen, P. J. (2009). Dynamically exploring internal mechanism of stock market by fuzzy-based support vector machines with high dimension input space and genetic algorithm. *Expert Systems with Applications*, 36(2), 1240-1248.
- [30] Cristianini, N., & Taylor, J. S. (2000). An introduction to support vector machines. New York: Cambridge University
- [31] Prasetyo, E., 2014, Data Mining Konsep dan Aplikasi Menggunakan MATLAB, Andi, Yogyakarta.
- [32] Yasin, H., Prahutama, A., & Utami, T. W. (2014). Prediksi Harga Saham Menggunakan Support Vector Regression Dengan Algoritma Grid Search. *Media Statistika*, 7(1), 29-35.
- [33] Makridakis, S. W. 1999. Metode dan Aplikasi Peramalan Edisi Kedua Jilid I, Erlangga.
- [34] Pesaran, M. H., & Timmermann, A. (1992). A simple nonparametric test of predictive performance. *Journal of Business & Economic Statistics*, 10(4), 461-465.
- [35] KDNuggets, C. S. (n.d.). Building Regression Models in R using Support Vector Regression. Retrieved June 04, 2017,

from <http://www.kdnuggets.com/2017/03/building-regression-models-support-vector-regression.html>

- [36] StackExchange. (n.d.). Which search range for determining SVM optimal C and gamma parameters? Retrieved June 04, 2017, from <https://stats.stackexchange.com/questions/43943/which-search-range-for-determining-svm-optimal-c-and-gamma-parameters>

(Halaman ini sengaja dikosongkan)

BIODATA PENULIS



Penulis lahir di Balikpapan pada tanggal 29 Juni 1996. Merupakan anak kedua dari 2 bersaudara. Penulis telah menempuh beberapa pendidikan formal yaitu; SD Patra Dharma 3 Balikpapan, SMPN 1 Balikpapan, dan SMAN 1 Balikpapan.

Pada tahun 2013 pasca kelulusan SMA, penulis melanjutkan pendidikan melalui jalur SNMPTN tulis di Jurusan Sistem Informasi FTIf – Institut Teknologi Sepuluh Nopember (ITS) Surabaya dan terdaftar sebagai mahasiswa dengan NRP 5213100045. Selama menjadi mahasiswa, penulis aktif dalam organisasi himpunan mahasiswa di Sistem Informasi ITS, yaitu menjadi staf Biro Komunitas di tahun kedua dan menjadi staf Ahli Biro Komunitas di tahun ketiga Himpunan Mahasiswa Sistem Informasi (HMSI). Selain itu, penulis sempat mengikuti Unit Kegiatan Mahasiswa (UKM) diluar jurusan yakni PSM ITS selama dua tahun pertama perkuliahan.

Penulis tertarik dengan bidang yang berkaitan dengan data kuantitatif seperti *Statistic* dan *Forecasting* sehingga mengambil bidang minat Rekayasa Data dan Intelegensia Bisnis (RDIB) di Jurusan Sistem Informasi ITS. Penulis dapat dihubungi melalui *email* farhan96naufal@gmail.com.

(Halaman ini sengaja dikosongkan)

LAMPIRAN A

Lampiran Pembagian Data Training dan Testing pada setiap Pintu Masuk

Table A-1 Pembagian pada dataset Ngurah Rai

	2008	2009	2010	2011	2012	2013	2014	2015	2016
Jan	147,319	173,919	178,358	208,337	249,728	229,561	278,685	288,755	343,663
Feb	159,681	146,192	191,362	201,457	209,160	236,971	269,367	333,072	367,024
Mar	159,886	168,036	191,125	202,539	222,950	247,024	268,418	294,758	354,778
Apr	154,777	188,189	184,230	224,423	222,657	239,400	277,925	309,888	367,370
May	167,342	190,697	199,401	208,832	220,508	244,874	285,965	287,141	394,443
Jun	178,258	200,503	224,695	245,248	241,108	275,452	329,654	357,712	405,686
Jul	190,662	235,042	252,110	279,219	271,371	297,723	358,907	381,890	482,201
Aug	195,758	232,164	243,222	252,698	253,970	309,051	336,628	298,638	437,929
Sep	189,247	218,245	232,516	252,855	255,717	305,429	352,017	379,397	442,304
Oct	189,142	225,606	229,651	244,421	252,716	266,453	339,200	366,759	423,140
Nov	172,813	184,622	196,856	220,341	237,874	296,990	293,858	262,180	396,150
Dec	176,901	221,604	222,497	248,336	264,366	292,961	341,111	363,780	440,369

Table A-2 Pembagian data pada dataset Batam

	2008	2009	2010	2011	2012	2013	2014	2015	2016
Jan	77,656	81,601	79,560	77,925	102,630	89,250	119,054	114,478	108,888
Feb	87,206	68,964	80,966	86,318	83,089	105,380	97,445	119,642	120,351
Mar	92,174	87,154	81,732	87,776	103,626	120,271	122,019	124,019	125,324
Apr	78,838	77,788	77,178	92,055	93,813	93,163	111,929	125,816	125,573
May	87,079	79,969	84,617	96,206	94,117	109,335	115,323	148,920	132,410
Jun	98,404	84,521	92,719	111,619	117,049	126,277	140,218	132,569	121,253
Jul	85,560	70,864	86,716	108,383	92,636	91,056	101,996	109,931	103,647
Aug	94,257	78,422	76,809	84,918	95,725	112,340	111,455	134,540	99,724
Sep	74,690	66,105	74,511	90,569	95,423	108,215	113,090	117,089	115,052
Oct	82,630	72,195	77,183	95,250	102,251	103,511	126,169	123,750	114,020
Nov	90,102	78,764	85,307	100,404	101,881	123,835	123,505	124,983	106,953
Dec	112,794	105,037	110,148	130,158	137,368	153,797	171,907	170,081	164,602

Table A-3 Pembagian data pada dataset Tanjung Uban

	2009	2010	2011	2012	2013	2014	2015	2016
Jan	23,916	21,604	22,663	30,546	22,921	28,811	20,753	21,484
Feb	19,502	23,718	25,662	23,440	27,756	25,090	28,977	27,642
Mar	24,749	27,100	28,523	28,471	29,844	27,009	23,722	25,577
Apr	23,816	22,281	26,206	25,784	22,087	24,205	22,211	23,018
May	23,431	26,349	25,487	24,498	23,729	22,204	24,026	23,338
Jun	28,918	29,928	32,372	32,780	30,164	30,867	27,247	31,465
Jul	25,722	27,000	31,694	28,693	25,067	31,102	28,181	20,389
Aug	29,542	26,653	32,806	32,547	32,368	31,388	34,193	29,491
Sep	21,729	23,187	25,208	25,406	23,866	23,661	24,337	25,051
Oct	24,265	25,435	27,097	28,355	23,846	25,882	19,333	23,145
Nov	20,829	26,029	25,425	25,003	24,577	22,733	20,389	21,984
Dec	29,810	34,661	34,210	31,024	31,929	27,909	30,641	33,041

Table A-4 Pembagian data pada dataset Husein Sastranegara

	2009	2010	2011	2012	2013	2014	2015	2016
Jan	4,851	6,444	9,383	9,600	13,782	16,257	10,373	10,964
Feb	4,605	6,809	8,747	10,667	11,966	14,560	13,008	8,402
Mar	5,651	7,155	9,057	13,101	16,745	21,463	15,130	15,828
Apr	6,915	6,885	9,732	12,639	13,921	13,490	16,884	30,806
May	8,288	8,156	9,397	12,597	17,968	14,588	18,902	16,699
Jun	9,728	7,680	11,079	15,417	16,498	16,899	15,314	8,881
Jul	8,911	8,409	11,806	11,642	7,667	6,166	6,619	9,453
Aug	7,079	7,218	6,507	7,084	8,720	10,545	10,323	12,500
Sep	3,491	5,227	6,916	13,577	14,658	14,068	10,531	14,995
Oct	5,661	9,570	9,126	7,366	12,072	15,018	10,722	17,340
Nov	6,334	6,321	11,155	14,901	18,116	16,539	14,858	12,755
Dec	7,484	10,404	12,380	18,145	24,205	20,799	16,983	22,533

Table A-5 Pembagian data pada dataset Tanjung Pinang


	2008	2009	2010	2011	2012	2013	2014	2015	2016
Jan	6,538	9,909	6,173	6,194	9,524	5,539	8,236	5,774	5,971
Feb	9,736	6,606	8,548	8,648	6,869	8,533	6,132	8,023	8,407
Mar	10,415	9,867	7,731	8,388	9,841	9,823	9,057	8,053	8,656
Apr	8,915	8,428	7,942	9,026	8,734	7,352	8,227	7,477	8,042
May	12,001	9,001	8,474	8,523	8,780	7,921	8,041	7,772	8,162
Jun	11,692	10,241	10,030	11,067	11,174	10,884	9,773	7,735	7,930
Jul	9,871	7,159	8,091	8,987	7,199	6,799	7,149	6,521	6,932
Aug	13,319	8,025	7,093	7,858	7,805	8,341	8,589	7,941	6,166
Sep	9,735	8,407	8,390	7,849	6,934	7,544	7,327	7,095	8,474
Oct	8,966	7,598	7,237	7,483	8,168	7,549	6,716	6,233	6,800
Nov	9,272	7,864	8,167	9,969	7,985	8,980	7,818	7,589	6,854
Dec	13,045	9,382	10,078	12,188	10,772	10,328	10,607	10,966	10,900

Table A-6 Pembagian data pada dataset Sepingguan


	2008	2009	2010	2011	2012	2013	2014	2015	2016
Jan	643	723	615	1,355	1,157	1,502	963	712	656
Feb	805	924	694	1,356	1,836	1,482	1,089	707	1,150
Mar	951	929	1,254	1,744	1,939	1,395	1244	809	714
Apr	992	850	899	1,283	1,333	1,493	1,106	631	555
May	911	772	780	1,158	1,272	1,410	1,074	540	749
Jun	984	822	891	1,295	1,276	1,220	1,425	765	576
Jul	1,148	950	846	1,137	1,289	1,381	848	572	1,675
Aug	1,202	1,005	841	1,124	1,510	1,514	1,265	574	2,502
Sep	846	815	889	1,311	1,052	1,558	1,125	663	451
Oct	988	848	1,104	1,242	1,502	1,488	1,141	595	405
Nov	1,111	782	1,116	1,408	1,445	1,293	1,015	684	800
Dec	764	565	895	1,194	1,217	1,168	861	613	840

LAMPIRAN B


Lampiran Hasil Transformasi pada Minitab untuk keenam pintu masuk




Gambar B-1 Hasil uji normalitas pada dataset Ngurah Rai




Gambar B-2 Hasil uji normalitas pada dataset Batam




Gambar B-3 Hasil uji normalitas pada dataset Tanjung Uban



Gambar B-4 Hasil uji normalitas pada dataset Husein Sastranegara



Gambar B-5 Hasil uji normalitas pada dataset Tanjung Pinang



Gambar B-6 Hasil uji normalitas pada dataset Sepingan

(Halaman ini sengaja dikosongkan)

LAMPIRAN C

Lampiran Hasil Transformasi pada Pintu Masuk Ngurah Rai, Tanjung Uban dan Tanjung Pinang

Table C-1 Hasil Transformasi pada dataset Ngurah Rai

	2008	2009	2010	2011	2012	2013	2014	2015	2016
Jan	11.9	12.07	12.09	12.25	12.43	12.34	12.54	12.57	12.75
Feb	11.98	11.89	12.16	12.21	12.25	12.38	12.5	12.72	12.81
Mar	11.98	12.03	12.16	12.22	12.31	12.42	12.5	12.59	12.78
Apr	11.95	12.15	12.12	12.32	12.31	12.39	12.54	12.64	12.81
May	12.03	12.16	12.2	12.25	12.3	12.41	12.56	12.57	12.89
Jun	12.09	12.21	12.32	12.41	12.39	12.53	12.71	12.79	12.91
Jul	12.16	12.37	12.44	12.54	12.51	12.6	12.79	12.85	13.09
Aug	12.18	12.36	12.4	12.44	12.44	12.64	12.73	12.61	12.99
Sep	12.15	12.29	12.36	12.44	12.45	12.63	12.77	12.85	13
Oct	12.15	12.33	12.34	12.41	12.44	12.49	12.73	12.81	12.96
Nov	12.06	12.13	12.19	12.3	12.38	12.6	12.59	12.48	12.89
Dec	12.08	12.31	12.31	12.42	12.49	12.59	12.74	12.8	13

Table C-2 Hasil Transformasi pada dataset Tanjung Uban

	2009	2010	2011	2012	2013	2014	2015	2016
Jan	10.08	9.98	10.03	10.33	10.04	10.27	9.94	9.98
Feb	9.88	10.07	10.15	10.06	10.23	10.13	10.27	10.23
Mar	10.12	10.21	10.26	10.26	10.30	10.20	10.07	10.15
Apr	10.08	10.01	10.17	10.16	10.00	10.09	10.01	10.04
May	10.06	10.18	10.15	10.11	10.07	10.01	10.09	10.06
Jun	10.27	10.31	10.39	10.40	10.31	10.34	10.21	10.36
Jul	10.16	10.20	10.36	10.26	10.13	10.35	10.25	9.92
Aug	10.29	10.19	10.40	10.39	10.38	10.35	10.44	10.29
Sep	9.99	10.05	10.13	10.14	10.08	10.07	10.10	10.13
Oct	10.10	10.14	10.21	10.25	10.08	10.16	9.87	10.05
Nov	9.94	10.17	10.14	10.13	10.11	10.03	9.92	10.00
Dec	10.30	10.45	10.44	10.34	10.37	10.24	10.33	10.41

Table C-3 Hasil Transformasi pada dataset Tanjung Pinang

	2008	2009	2010	2011	2012	2013	2014	2015	2016
Jan	8.79	9.20	8.73	8.73	9.16	8.62	9.02	8.66	8.69
Feb	9.18	8.80	9.05	9.07	8.83	9.05	8.72	8.99	9.04
Mar	9.25	9.20	8.95	9.03	9.19	9.19	9.11	8.99	9.07
Apr	9.10	9.04	8.98	9.11	9.07	8.90	9.02	8.92	8.99
May	9.39	9.11	9.04	9.05	9.08	8.98	8.99	8.96	9.01
Jun	9.37	9.23	9.21	9.31	9.32	9.30	9.19	8.95	8.98
Jul	9.20	8.88	9.00	9.10	8.88	8.82	8.87	8.78	8.84
Aug	9.50	8.99	8.87	8.97	8.96	9.03	9.06	8.98	8.73
Sep	9.18	9.04	9.03	8.97	8.84	8.93	8.90	8.87	9.04
Oct	9.10	8.94	8.89	8.92	9.01	8.93	8.81	8.74	8.82
Nov	9.13	8.97	9.01	9.21	8.99	9.10	8.96	8.93	8.83
Dec	9.48	9.15	9.22	9.41	9.28	9.24	9.27	9.30	9.30

(Halaman ini sengaja dikosongkan)

LAMPIRAN D

Lampiran Hasil Pelatihan Model Berdasarkan Parameter tertentu pada keenam pintu masuk

Table D-7 Training Parameter pada Klaster Tinggi

Training Parameter				
e	c	γ	error (Ngurah Rai)	error (Batam)
0.0	2	2	0.012085657	0.0170128628
0.1	2	2	0.010647565	0.0172401729
0.2	2	2	0.010002001	0.0168992671
0.3	2	2	0.009132148	0.0178193220
0.4	2	2	0.009165535	0.0184080873
0.5	2	2	0.009378867	0.0185559133
0.6	2	2	0.009182413	0.0178316148
0.7	2	2	0.009611660	0.0170596544
0.8	2	2	0.010386586	0.0167046990
0.9	2	2	0.011110923	0.0172102458
1.0	2	2	0.011676171	0.0189012605
0.0	4	2	0.012024719	0.0174032200
0.1	4	2	0.010623766	0.0173305224
0.2	4	2	0.010216830	0.0168979811
0.3	4	2	0.009240879	0.0176515907
0.4	4	2	0.009047319	0.0186168238
0.5	4	2	0.009679443	0.0188195787
0.6	4	2	0.009149684	0.0178905483
0.7	4	2	0.009667972	0.0176321776
0.8	4	2	0.010321891	0.0176392353
0.9	4	2	0.011489360	0.0178931336
1.0	4	2	0.011777010	0.0199185511
0.0	8	2	0.011652566	0.0178589118

<i>Training Parameter</i>				
e	c	γ	error (Ngurah Rai)	error (Batam)
0.1	8	2	0.010709989	0.0175400964
0.2	8	2	0.010317656	0.0169140394
0.3	8	2	0.009261370	0.0178092432
0.4	8	2	0.008913634	0.0185151855
0.5	8	2	0.009509533	0.0189933029
0.6	8	2	0.009303055	0.0179385172
0.7	8	2	0.009518136	0.0185118766
0.8	8	2	0.010839126	0.0185949346
0.9	8	2	0.011763497	0.0185921820
1.0	8	2	0.012352554	0.0213318430
0.0	16	2	0.011309454	0.0182856225
0.1	16	2	0.010576704	0.0175544683
0.2	16	2	0.010222300	0.0174039626
0.3	16	2	0.009237626	0.0177668411
0.4	16	2	0.008762671	0.0190954506
0.5	16	2	0.009163136	0.0194059669
0.6	16	2	0.009401217	0.0178811885
0.7	16	2	0.009648256	0.0191148515
0.8	16	2	0.011039967	0.0198935797
0.9	16	2	0.011798256	0.0201953048
1.0	16	2	0.012691674	0.0236361132
0.0	32	2	0.011152682	0.0191313751
0.1	32	2	0.010416778	0.0179250853
0.2	32	2	0.010155342	0.0176649964
0.3	32	2	0.009383629	0.0181092703
0.4	32	2	0.008672977	0.0194720476
0.5	32	2	0.009128708	0.0193731100
0.6	32	2	0.009808237	0.0181807253
0.7	32	2	0.010077700	0.0195976826
0.8	32	2	0.011246271	0.0202137197

<i>Training Parameter</i>				
e	c	γ	error (Ngurah Rai)	error (Batam)
0.9	32	2	0.011597808	0.0212527560
1.0	32	2	0.012751117	0.0243198403
0.0	64	2	0.010887436	0.0196241451
0.1	64	2	0.010261771	0.0186761448
0.2	64	2	0.009896633	0.0177156417
0.3	64	2	0.009327409	0.0183799445
0.4	64	2	0.008726591	0.0196045785
0.5	64	2	0.009189279	0.0191795014
0.6	64	2	0.010122137	0.0183031385
0.7	64	2	0.010412128	0.0197635180
0.8	64	2	0.011489241	0.0205099274
0.9	64	2	0.011450128	0.0215148669
1.0	64	2	0.012798121	0.0246288377
0.0	128	2	0.010652985	0.0195737763
0.1	128	2	0.010340545	0.0187358455
0.2	128	2	0.009848953	0.0181828601
0.3	128	2	0.009571098	0.0188563051
0.4	128	2	0.009085812	0.0195874535
0.5	128	2	0.009321166	0.0193458378
0.6	128	2	0.010148472	0.0185431321
0.7	128	2	0.010607872	0.0203541427
0.8	128	2	0.011487907	0.0218853896
0.9	128	2	0.011463965	0.0221915606
1.0	128	2	0.012944909	0.0247309733
0.0	256	2	0.010487324	0.0190376539
0.1	256	2	0.010438146	0.0185323074
0.2	256	2	0.010088346	0.0185743175
0.3	256	2	0.009773140	0.0192804895
0.4	256	2	0.008816245	0.0195329732
0.5	256	2	0.009482827	0.0196299680

<i>Training Parameter</i>				
e	c	γ	error (Ngurah Rai)	error (Batam)
0.6	256	2	0.010222167	0.0195762188
0.7	256	2	0.010789502	0.0209940429
0.8	256	2	0.011577255	0.0222937732
0.9	256	2	0.012118123	0.0232247738
1.0	256	2	0.013001941	0.0258117651
0.0	512	2	0.010542264	0.0186440750
0.1	512	2	0.010607398	0.0183756352
0.2	512	2	0.010075716	0.0188346640
0.3	512	2	0.009746251	0.0197775981
0.4	512	2	0.008803520	0.0195292139
0.5	512	2	0.009427224	0.0196950740
0.6	512	2	0.010500497	0.0198647531
0.7	512	2	0.010868907	0.0211963364
0.8	512	2	0.011661431	0.0225243211
0.9	512	2	0.012705161	0.0233416225
1.0	512	2	0.013001941	0.0263400794
0.0	1024	2	0.011470459	0.0183323617
0.1	1024	2	0.010726087	0.0186686953
0.2	1024	2	0.010192783	0.0192092989
0.3	1024	2	0.009743875	0.0200010878
0.4	1024	2	0.009055791	0.0199229209
0.5	1024	2	0.009305963	0.0198753984
0.6	1024	2	0.010448254	0.0202367558
0.7	1024	2	0.010822896	0.0221096300
0.8	1024	2	0.011336268	0.0225635084
0.9	1024	2	0.012677966	0.0235150432
1.0	1024	2	0.013001941	0.0274394991
0.0	2	4	0.011101097	0.0182949477
0.1	2	4	0.010718687	0.0177150235
0.2	2	4	0.010078872	0.0174535167

Training Parameter				
e	c	γ	error (Ngurah Rai)	error (Batam)
0.3	2	4	0.009285538	0.0184163921
0.4	2	4	0.008856272	0.0188725286
0.5	2	4	0.009626109	0.0190543733
0.6	2	4	0.009953568	0.0178357929
0.7	2	4	0.010222581	0.0179257631
0.8	2	4	0.011180827	0.0175575406
0.9	2	4	0.011647045	0.0181653404
1.0	2	4	0.013242377	0.0199502648
0.0	4	4	0.010644388	0.0183716726
0.1	4	4	0.010010713	0.0177518238
0.2	4	4	0.009724122	0.0176975084
0.3	4	4	0.009170400	0.0185745700
0.4	4	4	0.008665103	0.0189255481
0.5	4	4	0.009274035	0.0191357313
0.6	4	4	0.010002057	0.0183726940
0.7	4	4	0.010531778	0.0190477172
0.8	4	4	0.011372906	0.0190563936
0.9	4	4	0.012070386	0.0194495693
1.0	4	4	0.013295917	0.0214187286
0.0	8	4	0.010179818	0.0184597430
0.1	8	4	0.009595136	0.0180567824
0.2	8	4	0.009342068	0.0178087981
0.3	8	4	0.008793022	0.0189504177
0.4	8	4	0.008577468	0.0192695174
0.5	8	4	0.009059287	0.0193363435
0.6	8	4	0.009958210	0.0193047939
0.7	8	4	0.010733095	0.0202714558
0.8	8	4	0.011667624	0.0211199749
0.9	8	4	0.012153149	0.0218150745
1.0	8	4	0.013320333	0.0228075570

Training Parameter				
e	c	γ	error (Ngurah Rai)	error (Batam)
0.0	16	4	0.009516213	0.0181582216
0.1	16	4	0.009223322	0.0185990140
0.2	16	4	0.008696597	0.0184486229
0.3	16	4	0.008274660	0.0194518806
0.4	16	4	0.008028372	0.0195648741
0.5	16	4	0.009075897	0.0196763666
0.6	16	4	0.009721629	0.0198580467
0.7	16	4	0.010652377	0.0209718733
0.8	16	4	0.011731265	0.0214103494
0.9	16	4	0.012128317	0.0217811060
1.0	16	4	0.013320333	0.0230406687
0.0	32	4	0.009043869	0.0180520191
0.1	32	4	0.008574979	0.0188108387
0.2	32	4	0.007515126	0.0191451537
0.3	32	4	0.007509535	0.0202639675
0.4	32	4	0.007674889	0.0201110319
0.5	32	4	0.008775033	0.0199223171
0.6	32	4	0.008836816	0.0206113538
0.7	32	4	0.010448664	0.0218700009
0.8	32	4	0.011417416	0.0223706253
0.9	32	4	0.012183629	0.0232830439
1.0	32	4	0.013320333	0.0239433901
0.0	64	4	0.007173794	0.0180261055
0.1	64	4	0.006606616	0.0186535931
0.2	64	4	0.006484572	0.0197140352
0.3	64	4	0.006563618	0.0206134854
0.4	64	4	0.007200858	0.0204539570
0.5	64	4	0.008065300	0.0205054266
0.6	64	4	0.008463498	0.0211580288
0.7	64	4	0.009915913	0.0228034011

<i>Training Parameter</i>				
e	c	γ	error (Ngurah Rai)	error (Batam)
0.8	64	4	0.011119241	0.0237781371
0.9	64	4	0.012183629	0.0244558548
1.0	64	4	0.013320333	0.0256828565
0.0	128	4	0.005278804	0.0180877185
0.1	128	4	0.004778085	0.0183520936
0.2	128	4	0.005424188	0.0197986419
0.3	128	4	0.006100773	0.0207962542
0.4	128	4	0.006785777	0.0210156591
0.5	128	4	0.007044461	0.0211713535
0.6	128	4	0.007696782	0.0222018062
0.7	128	4	0.008829698	0.0237553651
0.8	128	4	0.011065729	0.0245561275
0.9	128	4	0.012183629	0.0255127121
1.0	128	4	0.013320333	0.0280265509
0.0	256	4	0.004713627	0.0188903698
0.1	256	4	0.004637736	0.0186728782
0.2	256	4	0.005217125	0.0197062051
0.3	256	4	0.005548704	0.0209622036
0.4	256	4	0.005938576	0.0212769449
0.5	256	4	0.006357894	0.0215695571
0.6	256	4	0.007397195	0.0231118209
0.7	256	4	0.008721071	0.0244846955
0.8	256	4	0.011065729	0.0264224733
0.9	256	4	0.012183629	0.0278099176
1.0	256	4	0.013320333	0.0313408890
0.0	512	4	0.004778005	0.0193894484
0.1	512	4	0.004652550	0.0188817560
0.2	512	4	0.004792645	0.0194686924
0.3	512	4	0.005312815	0.0208012921
0.4	512	4	0.005676553	0.0217256138

Training Parameter				
e	c	γ	error (Ngurah Rai)	error (Batam)
0.5	512	4	0.005980118	0.0218908563
0.6	512	4	0.007157894	0.0234532591
0.7	512	4	0.008700809	0.0245556715
0.8	512	4	0.011065729	0.0266079918
0.9	512	4	0.012183629	0.0292142082
1.0	512	4	0.013320333	0.0318024744
0.0	1024	4	0.004892776	0.0200081207
0.1	1024	4	0.004537102	0.0189820748
0.2	1024	4	0.004580010	0.0191367189
0.3	1024	4	0.005303416	0.0205737475
0.4	1024	4	0.005583961	0.0224899483
0.5	1024	4	0.005988896	0.0223949243
0.6	1024	4	0.007029209	0.0235713737
0.7	1024	4	0.008700809	0.0251511875
0.8	1024	4	0.011065729	0.0271828904
0.9	1024	4	0.012183629	0.0294985713
1.0	1024	4	0.013320333	0.0326461886
0.0	2	8	0.005770040	0.0181145489
0.1	2	8	0.005834597	0.0180946326
0.2	2	8	0.005880933	0.0183931754
0.3	2	8	0.006691923	0.0196683794
0.4	2	8	0.007301233	0.0196231737
0.5	2	8	0.008346613	0.0196227624
0.6	2	8	0.008806979	0.0198447906
0.7	2	8	0.009772358	0.0198572253
0.8	2	8	0.011328351	0.0197683951
0.9	2	8	0.012627429	0.0197543859
1.0	2	8	0.013718030	0.0209682937
0.0	4	8	0.004381527	0.0181340505
0.1	4	8	0.004766507	0.0183803399

<i>Training Parameter</i>				
e	c	γ	error (Ngurah Rai)	error (Batam)
0.2	4	8	0.005211848	0.0189395893
0.3	4	8	0.005837408	0.0200919544
0.4	4	8	0.006562531	0.0202699418
0.5	4	8	0.006845912	0.0207087724
0.6	4	8	0.008030773	0.0209658046
0.7	4	8	0.009351160	0.0213591228
0.8	4	8	0.011449003	0.0211791632
0.9	4	8	0.012634884	0.0216153864
1.0	4	8	0.013718030	0.0219843416
0.0	8	8	0.004353205	0.0184472107
0.1	8	8	0.004436586	0.0185573078
0.2	8	8	0.004727922	0.0191852754
0.3	8	8	0.005414662	0.0204923286
0.4	8	8	0.005788963	0.0213144582
0.5	8	8	0.006382795	0.0215226374
0.6	8	8	0.007607489	0.0218867262
0.7	8	8	0.009239517	0.0225156998
0.8	8	8	0.011449003	0.0227397425
0.9	8	8	0.012634884	0.0226901096
1.0	8	8	0.013718030	0.0228441985
0.0	16	8	0.004514094	0.0192839637
0.1	16	8	0.004355065	0.0191097995
0.2	16	8	0.004486529	0.0195230318
0.3	16	8	0.005453665	0.0205265868
0.4	16	8	0.005490527	0.0219636462
0.5	16	8	0.006386213	0.0220255098
0.6	16	8	0.007286597	0.0228968108
0.7	16	8	0.009239517	0.0236467438
0.8	16	8	0.011449003	0.0241506510
0.9	16	8	0.012634884	0.0242283672

<i>Training Parameter</i>				
e	c	γ	error (Ngurah Rai)	error (Batam)
1.0	16	8	0.013718030	0.0243441568
0.0	32	8	0.004554453	0.0206398010
0.1	32	8	0.004314860	0.0201672445
0.2	32	8	0.004385109	0.0198348802
0.3	32	8	0.004995004	0.0211048580
0.4	32	8	0.005368254	0.0226108143
0.5	32	8	0.005774069	0.0224836223
0.6	32	8	0.007315822	0.0235555691
0.7	32	8	0.009239517	0.0248772293
0.8	32	8	0.011449003	0.0256103213
0.9	32	8	0.012634884	0.0253624274
1.0	32	8	0.013718030	0.0269965761
0.0	64	8	0.004737063	0.0215550282
0.1	64	8	0.004524620	0.0213333878
0.2	64	8	0.004339355	0.0206107801
0.3	64	8	0.004784490	0.0214040927
0.4	64	8	0.005227343	0.0227862447
0.5	64	8	0.005459975	0.0230111779
0.6	64	8	0.007289168	0.0244016467
0.7	64	8	0.009239517	0.0258840288
0.8	64	8	0.011449003	0.0259521337
0.9	64	8	0.012634884	0.0271279478
1.0	64	8	0.013718030	0.0288468486
0.0	128	8	0.004944301	0.0222671082
0.1	128	8	0.004605401	0.0226161731
0.2	128	8	0.004434976	0.0204043430
0.3	128	8	0.004762144	0.0168905590
0.4	128	8	0.005197137	0.0198680624
0.5	128	8	0.005381860	0.0235674971
0.6	128	8	0.007309383	0.0282517004

<i>Training Parameter</i>				
e	c	γ	error (Ngurah Rai)	error (Batam)
0.7	128	8	0.009239517	0.0251496063
0.8	128	8	0.011449003	0.0263906739
0.9	128	8	0.012634884	0.0260785475
1.0	128	8	0.013718030	0.0303340361
0.0	256	8	0.005163089	0.0240480714
0.1	256	8	0.004948780	0.0238984395
0.2	256	8	0.004582825	0.0231616758
0.3	256	8	0.005029507	0.0226664116
0.4	256	8	0.005540777	0.0234145927
0.5	256	8	0.005349484	0.0241574960
0.6	256	8	0.007275208	0.0255362255
0.7	256	8	0.009239517	0.0275105436
0.8	256	8	0.011449003	0.0275301491
0.9	256	8	0.012634884	0.0295196434
1.0	256	8	0.013718030	0.0302007649
0.0	512	8	0.005269786	0.0252517934
0.1	512	8	0.005290780	0.0242372523
0.2	512	8	0.004793056	0.0244755311
0.3	512	8	0.005345607	0.0234906823
0.4	512	8	0.005965772	0.0241663295
0.5	512	8	0.005471637	0.0250677505
0.6	512	8	0.007266448	0.0263014249
0.7	512	8	0.009239517	0.0285118663
0.8	512	8	0.011449003	0.0284357108
0.9	512	8	0.012634884	0.0308580472
1.0	512	8	0.013718030	0.0311129022
0.0	1024	8	0.005447115	0.0257913747
0.1	1024	8	0.005544677	0.0251093688
0.2	1024	8	0.004864503	0.0250042497
0.3	1024	8	0.005611758	0.0241186975

Training Parameter				
e	c	γ	error (Ngurah Rai)	error (Batam)
0.4	1024	8	0.006428155	0.0242790780
0.5	1024	8	0.005545298	0.0255967562
0.6	1024	8	0.007253924	0.0272003125
0.7	1024	8	0.009239517	0.0298277491
0.8	1024	8	0.011449003	0.0295031233
0.9	1024	8	0.012634884	0.0305733396
1.0	1024	8	0.013718030	0.0307573559

Table D-8 Training Parameter pada Klaster Sedang

Training Parameter				
e	c	γ	error (Tanjung Uban)	error (Husein)
0.0	2	2	0.02106282	0.09373428
0.1	2	2	0.02104504	0.09303767
0.2	2	2	0.01984817	0.09691231
0.3	2	2	0.01936435	0.09749809
0.4	2	2	0.01873808	0.09383921
0.5	2	2	0.01937872	0.09670692
0.6	2	2	0.02035089	0.09942985
0.7	2	2	0.02077579	0.09778610
0.8	2	2	0.02025058	0.10358344
0.9	2	2	0.01970615	0.10813880
1.0	2	2	0.01856188	0.11141445
0.0	4	2	0.02102886	0.09311954
0.1	4	2	0.02159789	0.09453272
0.2	4	2	0.02057773	0.10010832
0.3	4	2	0.01991729	0.09863513
0.4	4	2	0.01903568	0.09414822
0.5	4	2	0.01962634	0.09864492

<i>Training Parameter</i>				
e	c	γ	error (Tanjung Uban)	error (Husein)
0.6	4	2	0.02061340	0.10343081
0.7	4	2	0.02095571	0.10097302
0.8	4	2	0.02065393	0.10284988
0.9	4	2	0.01979834	0.10544756
1.0	4	2	0.01876574	0.11146105
0.0	8	2	0.02161225	0.09396549
0.1	8	2	0.02175731	0.09700365
0.2	8	2	0.02084436	0.10116197
0.3	8	2	0.02019499	0.09750824
0.4	8	2	0.01951127	0.09667243
0.5	8	2	0.01991269	0.10169397
0.6	8	2	0.02146163	0.10642444
0.7	8	2	0.02122065	0.10488754
0.8	8	2	0.02103483	0.10624775
0.9	8	2	0.01989766	0.10498642
1.0	8	2	0.01898824	0.10914188
0.0	16	2	0.02192896	0.09883869
0.1	16	2	0.02190727	0.10000959
0.2	16	2	0.02181544	0.10003817
0.3	16	2	0.02068799	0.09900284
0.4	16	2	0.02005042	0.09768800
0.5	16	2	0.02052878	0.10033785
0.6	16	2	0.02212139	0.10711000
0.7	16	2	0.02181134	0.10574716
0.8	16	2	0.02152241	0.10639372
0.9	16	2	0.02042523	0.10624792
1.0	16	2	0.01947288	0.10833266
0.0	32	2	0.02233654	0.10183196
0.1	32	2	0.02253464	0.10229951
0.2	32	2	0.02297644	0.09990386

Training Parameter				
e	c	γ	error (Tanjung Uban)	error (Husein)
0.3	32	2	0.02167477	0.09990724
0.4	32	2	0.02112889	0.09807365
0.5	32	2	0.02143704	0.10184238
0.6	32	2	0.02247219	0.10419165
0.7	32	2	0.02169593	0.10437450
0.8	32	2	0.02121649	0.10427807
0.9	32	2	0.02017751	0.10632302
1.0	32	2	0.01930809	0.10755156
0.0	64	2	0.02292994	0.10404158
0.1	64	2	0.02331879	0.10384129
0.2	64	2	0.02376351	0.10387914
0.3	64	2	0.02314938	0.10271470
0.4	64	2	0.02265044	0.09943000
0.5	64	2	0.02272607	0.10030458
0.6	64	2	0.02257399	0.10049469
0.7	64	2	0.02152559	0.09791327
0.8	64	2	0.02059329	0.10078910
0.9	64	2	0.01995347	0.10412958
1.0	64	2	0.01946510	0.10252543
0.0	128	2	0.02356647	0.10365264
0.1	128	2	0.02419425	0.10691557
0.2	128	2	0.02479877	0.10680411
0.3	128	2	0.02396543	0.10528997
0.4	128	2	0.02375110	0.10277583
0.5	128	2	0.02330504	0.09988331
0.6	128	2	0.02301687	0.09591985
0.7	128	2	0.02212361	0.09575441
0.8	128	2	0.02057815	0.09930810
0.9	128	2	0.02076483	0.10941016
1.0	128	2	0.01990022	0.09466174

Training Parameter				
e	c	γ	error (Tanjung Uban)	error (Husein)
0.0	256	2	0.02476240	0.10397416
0.1	256	2	0.02653339	0.10995280
0.2	256	2	0.02532887	0.10955414
0.3	256	2	0.02499634	0.10643870
0.4	256	2	0.02489064	0.10455377
0.5	256	2	0.02397980	0.09944407
0.6	256	2	0.02411801	0.09322172
0.7	256	2	0.02255954	0.10030886
0.8	256	2	0.02070740	0.09807508
0.9	256	2	0.02210115	0.09887853
1.0	256	2	0.02224943	0.10411924
0.0	512	2	0.02734263	0.10981097
0.1	512	2	0.02882194	0.11387997
0.2	512	2	0.02770371	0.10885904
0.3	512	2	0.02696854	0.10690217
0.4	512	2	0.02647573	0.10566598
0.5	512	2	0.02462089	0.09995265
0.6	512	2	0.02488234	0.09015133
0.7	512	2	0.02312301	0.10215598
0.8	512	2	0.02101875	0.10832532
0.9	512	2	0.02256293	0.10837384
1.0	512	2	0.02287516	0.10724693
0.0	1024	2	0.03006301	0.11439021
0.1	1024	2	0.03079010	0.11223676
0.2	1024	2	0.02946378	0.11119043
0.3	1024	2	0.02822610	0.10934148
0.4	1024	2	0.02688267	0.10660518
0.5	1024	2	0.02504237	0.10412764
0.6	1024	2	0.02461742	0.09440515
0.7	1024	2	0.02341680	0.10602156

Training Parameter				
e	c	γ	error (Tanjung Uban)	error (Husein)
0.8	1024	2	0.02038380	0.11149024
0.9	1024	2	0.02241911	0.11753010
1.0	1024	2	0.02209353	0.12248629
0.0	2	4	0.02182192	0.09376441
0.1	2	4	0.02202449	0.09667285
0.2	2	4	0.02139932	0.10454259
0.3	2	4	0.02067929	0.10569864
0.4	2	4	0.01982033	0.09748701
0.5	2	4	0.02032968	0.10042362
0.6	2	4	0.02103025	0.10344233
0.7	2	4	0.02060528	0.10395371
0.8	2	4	0.02002440	0.10747610
0.9	2	4	0.01937984	0.11207486
1.0	2	4	0.01859801	0.11483987
0.0	4	4	0.02183615	0.09179298
0.1	4	4	0.02214989	0.09916779
0.2	4	4	0.02188682	0.10418776
0.3	4	4	0.02101574	0.10419708
0.4	4	4	0.02073047	0.10023446
0.5	4	4	0.02126322	0.10219346
0.6	4	4	0.02204965	0.10206326
0.7	4	4	0.02137217	0.10435900
0.8	4	4	0.02031573	0.10955673
0.9	4	4	0.01978979	0.11253950
1.0	4	4	0.01892709	0.11294469
0.0	8	4	0.02280084	0.09590721
0.1	8	4	0.02276468	0.09944625
0.2	8	4	0.02238510	0.10187569
0.3	8	4	0.02155432	0.10394376
0.4	8	4	0.02188672	0.10525317

Training Parameter				
e	c	γ	error (Tanjung Uban)	error (Husein)
0.5	8	4	0.02239056	0.10352164
0.6	8	4	0.02274017	0.10381791
0.7	8	4	0.02167644	0.10200784
0.8	8	4	0.02039760	0.10333841
0.9	8	4	0.01962937	0.10955204
1.0	8	4	0.01868221	0.11245820
0.0	16	4	0.02460726	0.09873704
0.1	16	4	0.02411674	0.10119250
0.2	16	4	0.02351488	0.10388400
0.3	16	4	0.02311033	0.10612442
0.4	16	4	0.02331147	0.10769494
0.5	16	4	0.02366815	0.10253630
0.6	16	4	0.02300517	0.09843378
0.7	16	4	0.02214545	0.09874286
0.8	16	4	0.02052541	0.10187996
0.9	16	4	0.02012839	0.10349531
1.0	16	4	0.01876317	0.10071590
0.0	32	4	0.02681216	0.10345608
0.1	32	4	0.02669495	0.10103084
0.2	32	4	0.02538468	0.10200664
0.3	32	4	0.02549232	0.10232296
0.4	32	4	0.02494971	0.10546008
0.5	32	4	0.02433207	0.10075298
0.6	32	4	0.02376045	0.09855161
0.7	32	4	0.02309740	0.10198538
0.8	32	4	0.02091837	0.10334374
0.9	32	4	0.01975791	0.10789445
1.0	32	4	0.01894039	0.10172803
0.0	64	4	0.02887045	0.11446966
0.1	64	4	0.02983880	0.10991889

<i>Training Parameter</i>				
e	c	γ	error (Tanjung Uban)	error (Husein)
0.2	64	4	0.02806890	0.10993777
0.3	64	4	0.02715629	0.10080221
0.4	64	4	0.02599401	0.10244725
0.5	64	4	0.02527632	0.10033500
0.6	64	4	0.02395657	0.09902493
0.7	64	4	0.02283087	0.09589244
0.8	64	4	0.02074844	0.10125728
0.9	64	4	0.01970634	0.10559968
1.0	64	4	0.01963409	0.10605916
0.0	128	4	0.03218303	0.11611463
0.1	128	4	0.03117361	0.12183311
0.2	128	4	0.02955732	0.11798740
0.3	128	4	0.02831053	0.10829333
0.4	128	4	0.02725776	0.10447328
0.5	128	4	0.02593732	0.10533082
0.6	128	4	0.02398496	0.10363245
0.7	128	4	0.02239839	0.09827198
0.8	128	4	0.02051826	0.08820033
0.9	128	4	0.01966814	0.09597908
1.0	128	4	0.01941922	0.10913456
0.0	256	4	0.03579397	0.12534107
0.1	256	4	0.03357649	0.13141283
0.2	256	4	0.03121579	0.12169200
0.3	256	4	0.02974555	0.11096151
0.4	256	4	0.02747647	0.10286468
0.5	256	4	0.02640600	0.10575297
0.6	256	4	0.02521196	0.10905091
0.7	256	4	0.02332532	0.10502309
0.8	256	4	0.02064085	0.08879956
0.9	256	4	0.01972984	0.09674648

<i>Training Parameter</i>				
e	c	γ	error (Tanjung Uban)	error (Husein)
1.0	256	4	0.01896611	0.12277064
0.0	512	4	0.03582019	0.13639008
0.1	512	4	0.03444275	0.14264848
0.2	512	4	0.03213865	0.12902401
0.3	512	4	0.02968550	0.11607331
0.4	512	4	0.02752568	0.10445241
0.5	512	4	0.02708957	0.10412279
0.6	512	4	0.02605356	0.11357055
0.7	512	4	0.02391821	0.11162248
0.8	512	4	0.02071968	0.10436402
0.9	512	4	0.01974755	0.10082030
1.0	512	4	0.01794640	0.12038201
0.0	1024	4	0.03509830	0.15291909
0.1	1024	4	0.03660653	0.14511669
0.2	1024	4	0.03399991	0.13966419
0.3	1024	4	0.03034480	0.12475520
0.4	1024	4	0.02833962	0.10962784
0.5	1024	4	0.02808735	0.10635213
0.6	1024	4	0.02679118	0.11423237
0.7	1024	4	0.02414962	0.11917048
0.8	1024	4	0.02246959	0.10497254
0.9	1024	4	0.02091372	0.09919794
1.0	1024	4	0.01797906	0.10652698
0.0	2	8	0.02313861	0.09424794
0.1	2	8	0.02307089	0.09638455
0.2	2	8	0.02266449	0.10016372
0.3	2	8	0.02214773	0.09917496
0.4	2	8	0.02179248	0.09819738
0.5	2	8	0.02238092	0.09370963
0.6	2	8	0.02257877	0.09390091

Training Parameter				
e	c	γ	error (Tanjung Uban)	error (Husein)
0.7	2	8	0.02151069	0.10246389
0.8	2	8	0.02014140	0.10714659
0.9	2	8	0.01931143	0.11217638
1.0	2	8	0.01794911	0.11326649
0.0	4	8	0.02513182	0.09710766
0.1	4	8	0.02486986	0.10398944
0.2	4	8	0.02436524	0.10664926
0.3	4	8	0.02375179	0.10198419
0.4	4	8	0.02341521	0.10221168
0.5	4	8	0.02443394	0.10077441
0.6	4	8	0.02325609	0.09462814
0.7	4	8	0.02206314	0.10138167
0.8	4	8	0.02071911	0.10121661
0.9	4	8	0.01965050	0.10542689
1.0	4	8	0.01844584	0.10812073
0.0	8	8	0.02740880	0.11199990
0.1	8	8	0.02782595	0.11479805
0.2	8	8	0.02702382	0.11800446
0.3	8	8	0.02594016	0.10721685
0.4	8	8	0.02568204	0.10109848
0.5	8	8	0.02460405	0.10147871
0.6	8	8	0.02349913	0.09986318
0.7	8	8	0.02214574	0.10426203
0.8	8	8	0.02059434	0.10284314
0.9	8	8	0.01988762	0.10542941
1.0	8	8	0.01852127	0.11066775
0.0	16	8	0.03061043	0.13032237
0.1	16	8	0.03045182	0.13038855
0.2	16	8	0.02904145	0.12855062
0.3	16	8	0.02808627	0.11763486

<i>Training Parameter</i>				
e	c	γ	error (Tanjung Uban)	error (Husein)
0.4	16	8	0.02670702	0.10490546
0.5	16	8	0.02558281	0.09911830
0.6	16	8	0.02392903	0.09805874
0.7	16	8	0.02213103	0.09922700
0.8	16	8	0.02038415	0.09813919
0.9	16	8	0.01987365	0.09850159
1.0	16	8	0.01866223	0.10360889
0.0	32	8	0.03342360	0.14473920
0.1	32	8	0.03236385	0.14460036
0.2	32	8	0.03099386	0.13341618
0.3	32	8	0.02895138	0.11935691
0.4	32	8	0.02657752	0.11169014
0.5	32	8	0.02626677	0.10446300
0.6	32	8	0.02423269	0.10032564
0.7	32	8	0.02185614	0.09699405
0.8	32	8	0.02082017	0.09867647
0.9	32	8	0.02000631	0.09534077
1.0	32	8	0.01878480	0.10431148
0.0	64	8	0.03466532	0.16360629
0.1	64	8	0.03339348	0.15157141
0.2	64	8	0.03200056	0.13728611
0.3	64	8	0.02909118	0.12356277
0.4	64	8	0.02699727	0.11706968
0.5	64	8	0.02627386	0.10825920
0.6	64	8	0.02475820	0.10262124
0.7	64	8	0.02253230	0.09710748
0.8	64	8	0.02136293	0.09803184
0.9	64	8	0.01983901	0.09858151
1.0	64	8	0.01861656	0.10563821
0.0	128	8	0.03573885	0.16843558

Training Parameter				
e	c	γ	error (Tanjung Uban)	error (Husein)
0.1	128	8	0.03640089	0.15949946
0.2	128	8	0.03334146	0.14700807
0.3	128	8	0.03080204	0.13369716
0.4	128	8	0.02821237	0.12079680
0.5	128	8	0.02679756	0.10940361
0.6	128	8	0.02504151	0.10913171
0.7	128	8	0.02302890	0.09559198
0.8	128	8	0.02210341	0.09435297
0.9	128	8	0.02031939	0.09965345
1.0	128	8	0.01854998	0.10184071
0.0	256	8	0.03635550	0.16872336
0.1	256	8	0.03735307	0.16167598
0.2	256	8	0.03406620	0.15555443
0.3	256	8	0.03216348	0.13824198
0.4	256	8	0.02916006	0.12349373
0.5	256	8	0.03094420	0.11408113
0.6	256	8	0.02573168	0.11186246
0.7	256	8	0.02388077	0.09580853
0.8	256	8	0.02273434	0.09424325
0.9	256	8	0.02106842	0.09734005
1.0	256	8	0.01896049	0.10191049
0.0	512	8	0.03797845	0.16656114
0.1	512	8	0.03861466	0.15845909
0.2	512	8	0.03586664	0.15554171
0.3	512	8	0.03362142	0.14141382
0.4	512	8	0.03015706	0.12491994
0.5	512	8	0.03244448	0.11326573
0.6	512	8	0.02683872	0.10660064
0.7	512	8	0.02626551	0.09443138
0.8	512	8	0.02525265	0.10344163

Training Parameter				
e	c	γ	error (Tanjung Uban)	error (Husein)
0.9	512	8	0.02253310	0.09992633
1.0	512	8	0.02070526	0.09611332
0.0	1024	8	0.03917284	0.16288502
0.1	1024	8	0.03967436	0.15599434
0.2	1024	8	0.03871996	0.14584465
0.3	1024	8	0.03450362	0.14184873
0.4	1024	8	0.03384135	0.12068949
0.5	1024	8	0.03288454	0.11514397
0.6	1024	8	0.03065197	0.10678735
0.7	1024	8	0.02891006	0.11030969
0.8	1024	8	0.02800657	0.12314066
0.9	1024	8	0.02556897	0.12327725
1.0	1024	8	0.02424054	0.09858646

Table D-9 Training Parameter pada Klaster Rendah

Training Parameter				
e	c	γ	error (Tanjung Png)	error (Sepinggan)
0.0	2	2	0.02956046	0.037773
0.1	2	2	0.02929918	0.036158
0.2	2	2	0.03012099	0.036307
0.3	2	2	0.03079085	0.035401
0.4	2	2	0.03033977	0.036990
0.5	2	2	0.03074775	0.038000
0.6	2	2	0.03207815	0.036701
0.7	2	2	0.03130277	0.038149
0.8	2	2	0.03149728	0.040358
0.9	2	2	0.03185329	0.042821
1.0	2	2	0.03252287	0.044781

Training Parameter				
e	c	γ	error (Tanjung Png)	error (Sepinggan)
0.0	4	2	0.02997778	0.037601
0.1	4	2	0.02927156	0.036365
0.2	4	2	0.02990294	0.036876
0.3	4	2	0.03094628	0.035740
0.4	4	2	0.03036063	0.037278
0.5	4	2	0.03113311	0.037171
0.6	4	2	0.03222531	0.036575
0.7	4	2	0.03282022	0.038513
0.8	4	2	0.03243599	0.040316
0.9	4	2	0.03277365	0.043365
1.0	4	2	0.03408279	0.045230
0.0	8	2	0.02993189	0.036861
0.1	8	2	0.02928152	0.036345
0.2	8	2	0.02961891	0.037140
0.3	8	2	0.03056141	0.036308
0.4	8	2	0.03033497	0.038646
0.5	8	2	0.03102054	0.036880
0.6	8	2	0.03284720	0.036742
0.7	8	2	0.03310723	0.038003
0.8	8	2	0.03294509	0.040697
0.9	8	2	0.03298502	0.042243
1.0	8	2	0.03343396	0.045062
0.0	16	2	0.03023577	0.036591
0.1	16	2	0.02960528	0.035783
0.2	16	2	0.02955655	0.037080
0.3	16	2	0.03021311	0.037098
0.4	16	2	0.03077754	0.040044
0.5	16	2	0.03159352	0.037134
0.6	16	2	0.03323719	0.036410
0.7	16	2	0.03348206	0.039400

Training Parameter				
e	c	γ	error (Tanjung Png)	error (Sepinggan)
0.8	16	2	0.03419758	0.040549
0.9	16	2	0.03328468	0.043122
1.0	16	2	0.03299553	0.046732
0.0	32	2	0.03125947	0.036442
0.1	32	2	0.02969992	0.035633
0.2	32	2	0.03009563	0.036833
0.3	32	2	0.03081666	0.037424
0.4	32	2	0.03098785	0.039487
0.5	32	2	0.03177212	0.037040
0.6	32	2	0.03301446	0.036810
0.7	32	2	0.03440882	0.040103
0.8	32	2	0.03554972	0.042227
0.9	32	2	0.03311986	0.045296
1.0	32	2	0.03308504	0.047606
0.0	64	2	0.03172490	0.035922
0.1	64	2	0.03084800	0.035703
0.2	64	2	0.03089151	0.035849
0.3	64	2	0.03128719	0.037244
0.4	64	2	0.03135249	0.037978
0.5	64	2	0.03167347	0.036165
0.6	64	2	0.03275565	0.037515
0.7	64	2	0.03419500	0.041132
0.8	64	2	0.03583299	0.043564
0.9	64	2	0.03384702	0.046990
1.0	64	2	0.03406619	0.050553
0.0	128	2	0.03207642	0.037196
0.1	128	2	0.03130767	0.035314
0.2	128	2	0.03145322	0.035769
0.3	128	2	0.03146068	0.037877
0.4	128	2	0.03158936	0.035522

Training Parameter				
e	c	γ	error (Tanjung Png)	error (Sepinggan)
0.5	128	2	0.03150853	0.035740
0.6	128	2	0.03333300	0.038267
0.7	128	2	0.03338893	0.042111
0.8	128	2	0.03509791	0.045649
0.9	128	2	0.03473844	0.049848
1.0	128	2	0.03582113	0.051935
0.0	256	2	0.03275250	0.035661
0.1	256	2	0.03155128	0.035617
0.2	256	2	0.03168240	0.036418
0.3	256	2	0.03172347	0.037426
0.4	256	2	0.03185053	0.034358
0.5	256	2	0.03201166	0.036221
0.6	256	2	0.03346447	0.038995
0.7	256	2	0.03352002	0.042252
0.8	256	2	0.03506472	0.047782
0.9	256	2	0.03557437	0.051268
1.0	256	2	0.03735476	0.054644
0.0	512	2	0.03241937	0.035223
0.1	512	2	0.03144214	0.036117
0.2	512	2	0.03151721	0.036595
0.3	512	2	0.03161726	0.038000
0.4	512	2	0.03200030	0.034093
0.5	512	2	0.03211837	0.035757
0.6	512	2	0.03299172	0.038863
0.7	512	2	0.03379840	0.042650
0.8	512	2	0.03532926	0.048031
0.9	512	2	0.03554083	0.054034
1.0	512	2	0.03758834	0.056748
0.0	1024	2	0.03226641	0.035004
0.1	1024	2	0.03134541	0.036202

Training Parameter				
e	c	γ	error (Tanjung Png)	error (Sepinggan)
0.2	1024	2	0.03111825	0.036215
0.3	1024	2	0.03188228	0.036191
0.4	1024	2	0.03239320	0.033925
0.5	1024	2	0.03245823	0.036133
0.6	1024	2	0.03388346	0.039344
0.7	1024	2	0.03450773	0.043409
0.8	1024	2	0.03506175	0.048555
0.9	1024	2	0.03585777	0.053613
1.0	1024	2	0.03791978	0.054790
0.0	2	4	0.02949439	0.036236
0.1	2	4	0.02865638	0.036288
0.2	2	4	0.02985817	0.037015
0.3	2	4	0.03041417	0.036694
0.4	2	4	0.03077436	0.036772
0.5	2	4	0.03171118	0.036034
0.6	2	4	0.03268435	0.036946
0.7	2	4	0.03187034	0.038524
0.8	2	4	0.03209920	0.041462
0.9	2	4	0.03069747	0.043439
1.0	2	4	0.03220078	0.046722
0.0	4	4	0.02974015	0.036839
0.1	4	4	0.02949507	0.036299
0.2	4	4	0.02993621	0.036417
0.3	4	4	0.03082476	0.037501
0.4	4	4	0.03124198	0.035594
0.5	4	4	0.03195990	0.035241
0.6	4	4	0.03306930	0.037339
0.7	4	4	0.03393157	0.039972
0.8	4	4	0.03402899	0.043146
0.9	4	4	0.03289341	0.046649

Training Parameter				
e	c	γ	error (Tanjung Png)	error (Sepinggan)
1.0	4	4	0.03358248	0.047593
0.0	8	4	0.03096260	0.036504
0.1	8	4	0.02992471	0.036607
0.2	8	4	0.03068467	0.036360
0.3	8	4	0.03123663	0.037931
0.4	8	4	0.03165387	0.033937
0.5	8	4	0.03208156	0.035621
0.6	8	4	0.03372809	0.039064
0.7	8	4	0.03489786	0.042143
0.8	8	4	0.03575049	0.045834
0.9	8	4	0.03548627	0.049523
1.0	8	4	0.03518693	0.050332
0.0	16	4	0.03207859	0.037037
0.1	16	4	0.03097153	0.036874
0.2	16	4	0.03118619	0.035860
0.3	16	4	0.03186295	0.036672
0.4	16	4	0.03218715	0.034389
0.5	16	4	0.03188136	0.036408
0.6	16	4	0.03413497	0.040390
0.7	16	4	0.03485249	0.044115
0.8	16	4	0.03576593	0.048134
0.9	16	4	0.03615298	0.050700
1.0	16	4	0.03616205	0.052878
0.0	32	4	0.03303154	0.037172
0.1	32	4	0.03187989	0.036138
0.2	32	4	0.03155678	0.036131
0.3	32	4	0.03190273	0.035946
0.4	32	4	0.03232454	0.034494
0.5	32	4	0.03265133	0.036669
0.6	32	4	0.03459047	0.040748

Training Parameter				
e	c	γ	error (Tanjung Png)	error (Sepinggan)
0.7	32	4	0.03571913	0.044861
0.8	32	4	0.03601817	0.049988
0.9	32	4	0.03669177	0.054307
1.0	32	4	0.03637154	0.056217
0.0	64	4	0.03334178	0.037734
0.1	64	4	0.03217187	0.036686
0.2	64	4	0.03164966	0.037405
0.3	64	4	0.03162180	0.035696
0.4	64	4	0.03261407	0.034899
0.5	64	4	0.03387547	0.037253
0.6	64	4	0.03456738	0.040581
0.7	64	4	0.03636328	0.044975
0.8	64	4	0.03676271	0.050467
0.9	64	4	0.03762555	0.054021
1.0	64	4	0.03720300	0.055186
0.0	128	4	0.03229271	0.038612
0.1	128	4	0.03078986	0.037987
0.2	128	4	0.03074060	0.038016
0.3	128	4	0.03103022	0.035378
0.4	128	4	0.03254193	0.035265
0.5	128	4	0.03475211	0.037414
0.6	128	4	0.03523023	0.041353
0.7	128	4	0.03670210	0.045956
0.8	128	4	0.03719909	0.051686
0.9	128	4	0.03735843	0.054078
1.0	128	4	0.03916831	0.054568
0.0	256	4	0.03161244	0.038823
0.1	256	4	0.02965728	0.037848
0.2	256	4	0.02992115	0.038015
0.3	256	4	0.03062924	0.035465

Training Parameter				
e	c	γ	error (Tanjung Png)	error (Sepinggan)
0.4	256	4	0.03260285	0.034729
0.5	256	4	0.03451721	0.036730
0.6	256	4	0.03622103	0.041035
0.7	256	4	0.03759744	0.046128
0.8	256	4	0.03599053	0.050628
0.9	256	4	0.03744240	0.052062
1.0	256	4	0.03846720	0.054767
0.0	512	4	0.03005276	0.038596
0.1	512	4	0.02855766	0.037238
0.2	512	4	0.02967814	0.037753
0.3	512	4	0.03077607	0.035042
0.4	512	4	0.03252355	0.034229
0.5	512	4	0.03440229	0.036374
0.6	512	4	0.03615739	0.040150
0.7	512	4	0.03835322	0.046048
0.8	512	4	0.03603419	0.049696
0.9	512	4	0.03697385	0.052577
1.0	512	4	0.03651480	0.054278
0.0	1024	4	0.02899679	0.038056
0.1	1024	4	0.02979863	0.037098
0.2	1024	4	0.03010185	0.037315
0.3	1024	4	0.03078512	0.034097
0.4	1024	4	0.03264386	0.033787
0.5	1024	4	0.03391051	0.035806
0.6	1024	4	0.03430777	0.038259
0.7	1024	4	0.03641300	0.044317
0.8	1024	4	0.03719780	0.049567
0.9	1024	4	0.03517370	0.053667
1.0	1024	4	0.03519788	0.053426
0.0	2	8	0.03073218	0.036616

Training Parameter				
e	c	γ	error (Tanjung Png)	error (Sepinggan)
0.1	2	8	0.02920400	0.036293
0.2	2	8	0.02984913	0.036512
0.3	2	8	0.03050654	0.035609
0.4	2	8	0.03173645	0.035204
0.5	2	8	0.03224581	0.036308
0.6	2	8	0.03274167	0.039333
0.7	2	8	0.03341425	0.041845
0.8	2	8	0.03387447	0.045118
0.9	2	8	0.03328402	0.048567
1.0	2	8	0.03343244	0.050147
0.0	4	8	0.03151223	0.037418
0.1	4	8	0.03022084	0.035663
0.2	4	8	0.03039137	0.035868
0.3	4	8	0.03064855	0.034954
0.4	4	8	0.03197113	0.034152
0.5	4	8	0.03288349	0.036751
0.6	4	8	0.03401131	0.039710
0.7	4	8	0.03512172	0.042433
0.8	4	8	0.03602850	0.046570
0.9	4	8	0.03640221	0.049468
1.0	4	8	0.03569730	0.051135
0.0	8	8	0.03157800	0.035659
0.1	8	8	0.03084972	0.035180
0.2	8	8	0.03043569	0.035941
0.3	8	8	0.03075640	0.033979
0.4	8	8	0.03238949	0.033632
0.5	8	8	0.03381504	0.037003
0.6	8	8	0.03487830	0.039650
0.7	8	8	0.03571418	0.042635
0.8	8	8	0.03650234	0.046680

Training Parameter				
e	c	γ	error (Tanjung Png)	error (Sepinggan)
0.9	8	8	0.03682617	0.049463
1.0	8	8	0.03633691	0.052374
0.0	16	8	0.03093835	0.033343
0.1	16	8	0.03139681	0.034111
0.2	16	8	0.03133231	0.035694
0.3	16	8	0.03151207	0.033245
0.4	16	8	0.03325776	0.033257
0.5	16	8	0.03476423	0.036208
0.6	16	8	0.03514356	0.038616
0.7	16	8	0.03704363	0.041858
0.8	16	8	0.03777467	0.047936
0.9	16	8	0.03675519	0.049004
1.0	16	8	0.03645289	0.050953
0.0	32	8	0.03026261	0.032424
0.1	32	8	0.03203564	0.033471
0.2	32	8	0.03199820	0.035601
0.3	32	8	0.03246641	0.033192
0.4	32	8	0.03384517	0.033489
0.5	32	8	0.03570880	0.034904
0.6	32	8	0.03598915	0.038275
0.7	32	8	0.03758653	0.041899
0.8	32	8	0.03872245	0.045849
0.9	32	8	0.03848195	0.048275
1.0	32	8	0.03831083	0.049141
0.0	64	8	0.03006379	0.035748
0.1	64	8	0.03125556	0.034030
0.2	64	8	0.03173017	0.037290
0.3	64	8	0.03228716	0.033289
0.4	64	8	0.03420173	0.034693
0.5	64	8	0.03642343	0.035137

Training Parameter				
e	c	γ	error (Tanjung Png)	error (Sepinggan)
0.6	64	8	0.03721238	0.039294
0.7	64	8	0.03934567	0.042747
0.8	64	8	0.03980670	0.044131
0.9	64	8	0.04129948	0.047302
1.0	64	8	0.03912802	0.046409
0.0	128	8	0.03113713	0.037699
0.1	128	8	0.03113628	0.035928
0.2	128	8	0.03170160	0.038528
0.3	128	8	0.03259487	0.037299
0.4	128	8	0.03454509	0.037861
0.5	128	8	0.03769345	0.037817
0.6	128	8	0.03818290	0.038895
0.7	128	8	0.03867155	0.041024
0.8	128	8	0.03999248	0.041701
0.9	128	8	0.04327130	0.043372
1.0	128	8	0.04112025	0.042648
0.0	256	8	0.03165441	0.040560
0.1	256	8	0.03142063	0.036670
0.2	256	8	0.03187384	0.039289
0.3	256	8	0.03304666	0.040596
0.4	256	8	0.03556404	0.039074
0.5	256	8	0.03893635	0.040283
0.6	256	8	0.03990266	0.039371
0.7	256	8	0.04027694	0.040929
0.8	256	8	0.04116918	0.040154
0.9	256	8	0.04538887	0.039864
1.0	256	8	0.04405844	0.041689
0.0	512	8	0.03295014	0.041249
0.1	512	8	0.03271198	0.040763
0.2	512	8	0.03229830	0.042441

Training Parameter				
e	c	γ	error (Tanjung Png)	error (Sepinggan)
0.3	512	8	0.03329270	0.042317
0.4	512	8	0.03643840	0.040592
0.5	512	8	0.04025963	0.041468
0.6	512	8	0.04264483	0.040544
0.7	512	8	0.04268628	0.040821
0.8	512	8	0.04287760	0.039034
0.9	512	8	0.04749368	0.044511
1.0	512	8	0.04724676	0.043667
0.0	1024	8	0.03509981	0.043410
0.1	1024	8	0.03392658	0.042497
0.2	1024	8	0.03286401	0.044314
0.3	1024	8	0.03385131	0.044439
0.4	1024	8	0.03702933	0.041848
0.5	1024	8	0.04154316	0.041010
0.6	1024	8	0.04437045	0.042014
0.7	1024	8	0.04437893	0.040733
0.8	1024	8	0.04501625	0.038284
0.9	1024	8	0.04961702	0.045940
1.0	1024	8	0.04879479	0.045359

LAMPIRAN E

Lampiran Hasil Data Aktual dan Data Prediksi pada setiap Pintu Masuk

Table E-1 Hasil Data Aktual dan Data Prediksi Ngurah Rai

Bulan	Aktual	Prediksi	Bulan	Aktual	Prediksi
Jan-08	147,319	149,974	Jan-13	229,561	234,087
Feb-08	159,681	152,098	Feb-13	236,971	233,678
Mar-08	159,886	156,655	Mar-13	247,024	237,949
Apr-08	154,777	163,459	Apr-13	239,400	247,175
May-08	167,342	171,808	May-13	244,874	260,581
Jun-08	178,258	180,401	Jun-13	275,452	276,230
Jul-08	190,662	187,484	Jul-13	297,723	291,204
Aug-08	195,758	191,329	Aug-13	309,051	302,295
Sep-08	189,247	190,939	Sep-13	305,429	307,131
Oct-08	189,142	186,607	Oct-13	266,453	305,169
Nov-08	172,813	179,906	Nov-13	296,990	297,935
Dec-08	176,901	173,127	Dec-13	292,961	288,284
Jan-09	173,919	168,528	Jan-14	278,685	279,283
Feb-09	146,192	167,834	Feb-14	269,367	273,296
Mar-09	168,036	171,993	Mar-14	268,418	271,585
Apr-09	188,189	181,068	Apr-14	277,925	274,268
May-09	190,697	194,046	May-14	285,965	289,202
Jun-09	200,503	208,639	Jun-14	329,654	327,981
Jul-09	235,042	221,478	Jul-14	358,907	353,341
Aug-09	232,164	229,051	Aug-14	336,628	356,290
Sep-09	218,245	229,207	Sep-14	352,017	346,317
Oct-09	225,606	222,302	Oct-14	339,200	332,764
Nov-09	184,622	211,035	Nov-14	293,858	319,774

Bulan	Aktual	Prediksi	Bulan	Aktual	Prediksi
Dec-09	221,604	199,149	Dec-14	341,111	310,634
Jan-10	178,358	190,004	Jan-15	288,755	305,566
Feb-10	191,362	185,812	Feb-15	333,072	301,110
Mar-10	191,125	187,537	Mar-15	294,758	297,985
Apr-10	184,230	194,968	Apr-15	309,888	304,102
May-10	199,401	206,703	May-15	287,141	324,776
Jun-10	224,695	220,103	Jun-15	357,712	353,303
Jul-10	252,110	231,649	Jul-15	381,890	375,187
Aug-10	243,222	238,030	Aug-15	298,638	382,036
Sep-10	232,516	237,566	Sep-15	379,397	375,157
Oct-10	229,651	231,046	Oct-15	366,759	360,454
Nov-10	196,856	221,266	Nov-15	262,180	347,510
Dec-10	222,497	211,690	Dec-15	363,780	344,435
Jan-11	208,337	205,227	Jan-16	343,663	349,700
Feb-11	201,457	203,638	Feb-16	367,024	355,507
Mar-11	202,539	207,488	Mar-16	354,778	360,375
Apr-11	224,423	216,215	Apr-16	367,370	370,823
May-11	208,832	228,182	May-16	394,443	390,499
Jun-11	245,248	240,804	Jun-16	405,686	415,019
Jul-11	279,219	251,063	Jul-16	482,201	435,992
Aug-11	252,698	256,419	Aug-16	437,929	444,587
Sep-11	252,855	255,749	Sep-16	442,304	435,892
Oct-11	244,421	249,761	Oct-16	423,140	418,767
Nov-11	220,341	240,580	Nov-16	396,150	414,285
Dec-11	248,336	230,858	Dec-16	440,369	435,870
Jan-12	249,728	222,929			
Feb-12	209,160	218,371			

Bulan	Aktual	Prediksi	Bulan	Aktual	Prediksi
Mar-12	222,950	217,889			
Apr-12	222,657	221,372			
May-12	220,508	227,952			
Jun-12	241,108	236,081			
Jul-12	271,371	243,772			
Aug-12	253,970	249,058			
Sep-12	255,717	250,639			
Oct-12	252,716	248,406			
Nov-12	237,874	243,514			
Dec-12	264,366	237,994			

Table E-2 Hasil Data Aktual dan Data Prediksi Batam

Bulan	Aktual	Prediksi	Bulan	Aktual	Prediksi
Jan-08	77,656	81,966	Jan-13	89,250	110,364
Feb-08	87,206	84,374	Feb-13	105,380	110,477
Mar-08	92,174	87,069	Mar-13	120,271	109,314
Apr-08	78,838	89,445	Apr-13	93,163	107,402
May-08	87,079	90,977	May-13	109,335	105,538
Jun-08	98,404	91,371	Jun-13	126,277	104,555
Jul-08	85,560	90,653	Jul-13	91,056	105,060
Aug-08	94,257	89,154	Aug-13	112,340	107,239
Sep-08	74,690	87,396	Sep-13	108,215	110,778
Oct-08	82,630	85,898	Oct-13	103,511	114,935
Nov-08	90,102	84,997	Nov-13	123,835	118,739
Dec-08	112,794	84,720	Dec-13	153,797	121,259
Jan-09	81,601	84,786	Jan-14	119,054	121,850
Feb-09	68,964	84,721	Feb-14	97,445	120,313

Bulan	Aktual	Prediksi	Bulan	Aktual	Prediksi
Mar-09	87,154	84,062	Mar-14	122,019	116,920
Apr-09	77,788	82,575	Apr-14	111,929	112,302
May-09	79,969	80,382	May-14	115,323	117,130
Jun-09	84,521	77,956	Jun-14	140,218	128,707
Jul-09	70,864	75,970	Jul-14	101,996	118,602
Aug-09	78,422	75,047	Aug-14	111,455	109,641
Sep-09	66,105	75,519	Sep-14	113,090	114,900
Oct-09	72,195	77,293	Oct-14	126,169	124,365
Nov-09	78,764	79,876	Nov-14	123,505	125,796
Dec-09	105,037	82,558	Dec-14	171,907	121,192
Jan-10	79,560	84,669	Jan-15	114,478	117,775
Feb-10	80,966	85,796	Feb-15	119,642	117,836
Mar-10	81,732	85,880	Mar-15	124,019	122,218
Apr-10	77,178	85,158	Apr-15	125,816	130,608
May-10	84,617	84,005	May-15	148,920	135,853
Jun-10	92,719	82,757	Jun-15	132,569	130,762
Jul-10	86,716	81,616	Jul-15	109,931	120,230
Aug-10	76,809	80,668	Aug-15	134,540	115,332
Sep-10	74,511	79,986	Sep-15	117,089	118,901
Oct-10	77,183	79,738	Oct-15	123,750	124,867
Nov-10	85,307	80,216	Nov-15	124,983	126,789
Dec-10	110,148	81,747	Dec-15	170,081	123,355
Jan-11	77,925	84,518	Jan-16	108,888	118,872
Feb-11	86,318	88,397	Feb-16	120,351	118,548
Mar-11	87,776	92,875	Mar-16	125,324	123,513
Apr-11	92,055	97,160	Apr-16	125,573	130,161
May-11	96,206	100,426	May-16	132,410	130,611

Bulan	Aktual	Prediksi	Bulan	Aktual	Prediksi
Jun-11	111,619	102,101	Jun-16	121,253	119,438
Jul-11	108,383	102,088	Jul-16	103,647	105,454
Aug-11	84,918	100,790	Aug-16	99,724	103,138
Sep-11	90,569	98,954	Sep-16	115,052	109,340
Oct-11	95,250	97,373	Oct-16	114,020	112,206
Nov-11	100,404	96,594	Nov-16	106,953	122,452
Dec-11	130,158	96,741	Dec-16	164,602	162,793
Jan-12	102,630	97,527			
Feb-12	83,089	98,435			
Mar-12	103,626	98,975			
Apr-12	93,813	98,916			
May-12	94,117	98,383			
Jun-12	117,049	97,805			
Jul-12	92,636	97,729			
Aug-12	95,725	98,591			
Sep-12	95,423	100,524			
Oct-12	102,251	103,282			
Nov-12	101,881	106,300			
Dec-12	137,368	108,867			

Table E-3 Hasil Data Aktual dan Data Prediksi Tanjung Uban

Bulan	Aktual	Prediksi	Bulan	Aktual	Prediksi
Jan-09	23,916	22,679	Jan-13	22,921	25,758
Feb-09	19,502	22,619	Feb-13	27,756	26,318
Mar-09	24,749	23,468	Mar-13	29,844	27,162
Apr-09	23,816	24,889	Apr-13	22,087	27,846
May-09	23,431	26,349	May-13	23,729	27,971

Bulan	Aktual	Prediksi	Bulan	Aktual	Prediksi
Jun-09	28,918	27,235	Jun-13	30,164	27,415
Jul-09	25,722	27,128	Jul-13	25,067	26,434
Aug-09	29,542	26,061	Aug-13	32,368	25,500
Sep-09	21,729	24,486	Sep-13	23,866	25,037
Oct-09	24,265	23,009	Oct-13	23,846	25,225
Nov-09	20,829	22,108	Nov-13	24,577	25,919
Dec-09	29,810	22,031	Dec-13	31,929	26,676
Jan-10	21,604	22,786	Jan-14	28,811	26,959
Feb-10	23,718	24,152	Feb-14	25,090	26,508
Mar-10	27,100	25,696	Mar-14	27,009	25,609
Apr-10	22,281	26,876	Apr-14	24,205	24,990
May-10	26,349	27,298	May-14	22,204	25,493
Jun-10	29,928	26,934	Jun-14	30,867	27,880
Jul-10	27,000	26,112	Jul-14	31,102	32,801
Aug-10	26,653	25,272	Aug-14	31,388	26,840
Sep-10	23,187	24,725	Sep-14	23,661	26,195
Oct-10	25,435	24,556	Oct-14	25,882	25,203
Nov-10	26,029	24,680	Nov-14	22,733	24,238
Dec-10	34,661	24,961	Dec-14	27,909	23,865
Jan-11	22,663	25,336	Jan-15	20,753	24,269
Feb-11	25,662	25,857	Feb-15	28,977	24,779
Mar-11	28,523	26,620	Mar-15	23,722	24,430
Apr-11	26,206	27,639	Apr-15	22,211	23,714
May-11	25,487	28,753	May-15	24,026	24,859
Jun-11	32,372	29,655	Jun-15	27,247	29,219
Jul-11	31,694	30,051	Jul-15	28,181	32,955
Aug-11	32,806	29,865	Aug-15	34,193	29,240

Bulan	Aktual	Prediksi	Bulan	Aktual	Prediksi
Sep-11	25,208	29,276	Sep-15	24,337	22,530
Oct-11	27,097	28,579	Oct-15	19,333	20,756
Nov-11	25,425	27,987	Nov-15	20,389	23,844
Dec-11	34,210	27,561	Dec-15	30,641	26,201
Jan-12	30,546	27,259	Jan-16	21,484	25,126
Feb-12	23,440	27,053	Feb-16	27,642	23,637
Mar-12	28,471	26,996	Mar-16	25,577	23,039
Apr-12	25,784	27,193	Apr-16	23,018	24,352
May-12	24,498	27,678	May-16	23,338	27,291
Jun-12	32,780	28,325	Jun-16	31,465	26,796
Jul-12	28,693	28,834	Jul-16	20,389	23,842
Aug-12	32,547	28,879	Aug-16	29,491	25,220
Sep-12	25,406	28,325	Sep-16	25,051	28,987
Oct-12	28,355	27,354	Oct-16	23,145	27,065
Nov-12	25,003	26,367	Nov-16	21,984	24,005
Dec-12	31,024	25,762	Dec-16	33,041	28,255

Table E-4 Hasil Data Aktual dan Data Prediksi Husein Sastranegara

Bulan	Aktual	Prediksi	Bulan	Aktual	Prediksi
Jan-09	4,851	7,913	Jan-13	13,782	14,940
Feb-09	4,605	7,802	Feb-13	11,966	15,423
Mar-09	5,651	7,683	Mar-13	16,745	15,389
Apr-09	6,915	7,558	Apr-13	13,921	14,873
May-09	8,288	7,430	May-13	17,968	14,037
Jun-09	9,728	7,301	Jun-13	16,498	13,132
Jul-09	8,911	7,175	Jul-13	7,667	12,435
Aug-09	7,079	7,056	Aug-13	8,720	12,181

Bulan	Aktual	Prediksi	Bulan	Aktual	Prediksi
Sep-09	3,491	6,947	Sep-13	14,658	12,497
Oct-09	5,661	6,855	Oct-13	12,072	13,374
Nov-09	6,334	6,786	Nov-13	18,116	14,657
Dec-09	7,484	6,749	Dec-13	24,205	16,079
Jan-10	6,444	6,754	Jan-14	16,257	17,312
Feb-10	6,809	6,809	Feb-14	14,560	18,038
Mar-10	7,155	6,925	Mar-14	21,463	18,007
Apr-10	6,885	7,106	Apr-14	13,490	17,085
May-10	8,156	7,352	May-14	14,588	15,275
Jun-10	7,680	7,656	Jun-14	16,899	12,709
Jul-10	8,409	8,000	Jul-14	6,166	9,622
Aug-10	7,218	8,355	Aug-14	10,545	14,489
Sep-10	5,227	8,684	Sep-14	14,068	16,202
Oct-10	9,570	8,948	Oct-14	15,018	17,995
Nov-10	6,321	9,108	Nov-14	16,539	18,441
Dec-10	10,404	9,138	Dec-14	20,799	16,855
Jan-11	9,383	9,031	Jan-15	10,373	14,316
Feb-11	8,747	8,808	Feb-15	13,008	12,835
Mar-11	9,057	8,520	Mar-15	15,130	13,312
Apr-11	9,732	8,241	Apr-15	16,884	14,653
May-11	9,397	8,064	May-15	18,902	14,958
Jun-11	11,079	8,077	Jun-15	15,314	13,310
Jul-11	11,806	8,348	Jul-15	6,619	10,561
Aug-11	6,507	8,900	Aug-15	10,323	8,920
Sep-11	6,916	9,703	Sep-15	10,531	10,479
Oct-11	9,126	10,666	Oct-15	10,722	14,664
Nov-11	11,155	11,650	Nov-15	14,858	16,906

Bulan	Aktual	Prediksi	Bulan	Aktual	Prediksi
Dec-11	12,380	12,497	Dec-15	16,983	13,042
Jan-12	9,600	13,058	Jan-16	10,964	7,022
Feb-12	10,667	13,235	Feb-16	8,402	8,855
Mar-12	13,101	13,011	Mar-16	15,828	19,774
Apr-12	12,639	12,458	Apr-16	30,806	26,862
May-12	12,597	11,731	May-16	16,699	20,643
Jun-12	15,417	11,039	Jun-16	8,881	9,206
Jul-12	11,642	10,589	Jul-16	9,453	5,510
Aug-12	7,084	10,543	Aug-16	12,500	10,024
Sep-12	13,577	10,966	Sep-16	14,995	14,702
Oct-12	7,366	11,808	Oct-16	17,340	16,057
Nov-12	14,901	12,908	Nov-16	12,755	16,697
Dec-12	18,145	14,035	Dec-16	22,533	18,589

Table E-5 Hasil Data Aktual dan Data Prediksi Tanjung Pinang

Bulan	Aktual	Prediksi	Bulan	Aktual	Prediksi
Jan-08	6,538	6,656	Jan-13	5,539	8,410
Feb-08	9,736	8,525	Feb-13	8,533	8,382
Mar-08	10,415	10,248	Mar-13	9,823	8,244
Apr-08	8,915	11,409	Apr-13	7,352	8,036
May-08	12,001	11,787	May-13	7,921	7,815
Jun-08	11,692	11,485	Jun-13	10,884	7,637
Jul-08	9,871	10,823	Jul-13	6,799	7,544
Aug-08	13,319	10,136	Aug-13	8,341	7,560
Sep-08	9,735	9,643	Sep-13	7,544	7,680
Oct-08	8,966	9,421	Oct-13	7,549	7,874
Nov-08	9,272	9,439	Nov-13	8,980	8,090

Bulan	Aktual	Prediksi	Bulan	Aktual	Prediksi
Dec-08	13,045	9,590	Dec-13	10,328	8,274
Jan-09	9,909	9,734	Jan-14	8,236	8,384
Feb-09	6,606	9,745	Feb-14	6,132	8,415
Mar-09	9,867	9,567	Mar-14	9,057	8,396
Apr-09	8,428	9236	Apr-14	8,227	8,376
May-09	9,001	8,842	May-14	8,041	8,172
Jun-09	10,241	8,482	Jun-14	9,773	9,617
Jul-09	7,159	8,219	Jul-14	7,149	9,468
Aug-09	8,025	8,069	Aug-14	8,589	8,452
Sep-09	8,407	8,010	Sep-14	7,327	7,210
Oct-09	7,598	8,002	Oct-14	6,716	6,825
Nov-09	7,864	8,006	Nov-14	7,818	7,735
Dec-09	9,382	8,003	Dec-14	10,607	8,763
Jan-10	6,173	7,994	Jan-15	5,774	8,548
Feb-10	8,548	7,996	Feb-15	8,023	7,979
Mar-10	7,731	8,025	Mar-15	8,053	7,924
Apr-10	7,942	8,085	Apr-15	7,477	7,915
May-10	8,474	8,160	May-15	7,772	7,648
Jun-10	10,030	8,220	Jun-15	7,735	7,612
Jul-10	8,091	8,237	Jul-15	6,521	7,935
Aug-10	7,093	8,199	Aug-15	7,941	7,814
Sep-10	8,390	8,121	Sep-15	7,095	6,982
Oct-10	7,237	8,044	Oct-15	6,233	6,625
Nov-10	8,167	8,022	Nov-15	7,589	7,468
Dec-10	10,078	8,094	Dec-15	10,966	8,682
Jan-11	6,194	8,265	Jan-16	5,971	8,955
Feb-11	8,648	8,495	Feb-16	8,407	8,543

Bulan	Aktual	Prediksi	Bulan	Aktual	Prediksi
Mar-11	8,388	8,702	Mar-16	8,656	8,199
Apr-11	9,026	8,791	Apr-16	8,042	8,172
May-11	8,523	8,705	May-16	8,162	8,295
Jun-11	11,067	8,470	Jun-16	7,930	7,803
Jul-11	8,987	8,191	Jul-16	6,932	6,822
Aug-11	7,858	8,000	Aug-16	6,166	6,579
Sep-11	7,849	8,005	Sep-16	8,474	7,040
Oct-11	7,483	8,252	Oct-16	6,800	6,910
Nov-11	9,969	8,709	Nov-16	6,854	6,966
Dec-11	12,188	9,253	Dec-16	10,900	10,726
Jan-12	9,524	9,696			
Feb-12	6,869	9,858			
Mar-12	9,841	9,666			
Apr-12	8,734	9,199			
May-12	8,780	8,627			
Jun-12	11,174	8,123			
Jul-12	7,199	7,792			
Aug-12	7,805	7,667			
Sep-12	6,934	7,725			
Oct-12	8,168	7,905			
Nov-12	7,985	8,129			
Dec-12	10,772	8,317			

Table E-6 Hasil Data Aktual dan Data Prediksi Sepingguan

Bulan	Aktual	Prediksi	Bulan	Aktual	Prediksi
Jan-08	643	699	Jan-13	1,502	1,452
Feb-08	805	805	Feb-13	1,482	1,434
Mar-08	951	906	Mar-13	1,395	1,415
Apr-08	992	992	Apr-13	1,493	1,406
May-08	911	1,057	May-13	1,410	1,410
Jun-08	984	1,096	Jun-13	1,220	1,424
Jul-08	1,148	1,107	Jul-13	1,381	1,439
Aug-08	1,202	1,090	Aug-13	1,514	1,440
Sep-08	846	1,047	Sep-13	1,558	1,417
Oct-08	988	988	Oct-13	1,488	1,367
Nov-08	1,111	922	Nov-13	1,293	1,293
Dec-08	764	862	Dec-13	1,168	1,210
Jan-09	723	820	Jan-14	963	1,137
Feb-09	924	804	Feb-14	1,089	1,089
Mar-09	929	816	Mar-14	1,244	1,078
Apr-09	850	850	Apr-14	1,106	1,106
May-09	772	894	May-14	1,074	1,074
Jun-09	822	932	Jun-14	1,425	1,356
Jul-09	950	950	Jul-14	848	1,381
Aug-09	1,005	939	Aug-14	1,265	1,265
Sep-09	815	901	Sep-14	1,125	1,181
Oct-09	848	843	Oct-14	1,141	1,133
Nov-09	782	782	Nov-14	1,015	1,015
Dec-09	565	733	Dec-14	861	830
Jan-10	615	707	Jan-15	712	712
Feb-10	694	706	Feb-15	707	707

Bulan	Aktual	Prediksi	Bulan	Aktual	Prediksi
Mar-10	1,254	726	Mar-15	809	704
Apr-10	899	756	Apr-15	631	631
May-10	780	788	May-15	540	563
Jun-10	891	817	Jun-15	765	559
Jul-10	846	846	Jul-15	572	572
Aug-10	841	885	Aug-15	574	574
Sep-10	889	942	Sep-15	663	596
Oct-10	1,104	1,021	Oct-15	595	617
Nov-10	1,116	1,116	Nov-15	684	600
Dec-10	895	1,212	Dec-15	613	613
Jan-11	1,355	1,289	Jan-16	656	729
Feb-11	1,356	1,332	Feb-16	1,150	999
Mar-11	1,744	1,331	Mar-16	714	714
Apr-11	1,283	1,292	Apr-16	555	564
May-11	1,158	1,232	May-16	749	749
Jun-11	1,295	1,173	Jun-16	576	676
Jul-11	1,137	1,137	Jul-16	1,675	1,675
Aug-11	1,124	1,138	Aug-16	2,502	2,004
Sep-11	1,311	1,177	Sep-16	451	796
Oct-11	1,242	1,242	Oct-16	405	405
Nov-11	1,408	1,314	Nov-16	800	527
Dec-11	1,194	1,373	Dec-16	840	840
Jan-12	1,157	1,404			
Feb-12	1,836	1,402			
Mar-12	1,939	1,374			
Apr-12	1,333	1,333			
May-12	1,272	1,297			

Bulan	Aktual	Prediksi	Bulan	Aktual	Prediksi
Jun-12	1,276	1,280			
Jul-12	1,289	1,289			
Aug-12	1,510	1,321			
Sep-12	1,052	1,367			
Oct-12	1,502	1,412			
Nov-12	1,445	1,445			
Dec-12	1,217	1,458			

LAMPIRAN F

Lampiran Hasil Peramalan untuk Periode Kedepan pada tahun 2017

Table F-1 Hasil Peramalan Periode Kedepan dataset Ngurah Rai

Bulan	Prediksi
Jan-17	471,970
Feb-17	490,240
Mar-17	471,795
Apr-17	432,276
May-17	396,289
Jun-17	373,981
Jul-17	363,407
Aug-17	359,435
Sep-17	358,233
Oct-17	357,943
Nov-17	357,886
Dec-17	357,875

Table F-2 Hasil Peramalan Periode Kedepan dataset Batam

Bulan	Prediksi
Jan-17	106,428
Feb-17	108,703
Mar-17	122,607
Apr-17	123,294
May-17	124,300
Jun-17	116,783
Jul-17	103,937
Aug-17	103,455
Sep-17	115,869

Bulan	Prediksi
Oct-17	110,923
Nov-17	137,991
Dec-17	156,402

Table F-3 Hasil Peramalan Periode Kedepan dataset Tanjung Uban

Bulan	Prediksi
Jan-17	28,542
Feb-17	28,623
Mar-17	27,937
Apr-17	27,138
May-17	26,605
Jun-17	30,013
Jul-17	23,767
Aug-17	26,773
Sep-17	28,997
Oct-17	23,740
Nov-17	23,038
Dec-17	30,483

Table F-4 Hasil Peramalan Periode Kedepan dataset Husein Sastranegara

Bulan	Prediksi
Jan-17	11,453
Feb-17	13,855
Mar-17	15,130
Apr-17	22,874
May-17	21,327
Jun-17	19,366

Bulan	Prediksi
Jul-17	17,637
Aug-17	16,437
Sep-17	15,749
Oct-17	15,415
Nov-17	15,276
Dec-17	15,225

Table F-5 Hasil Peramalan Periode Kedepan dataset Tanjung Pinang

Bulan	Prediksi
Jan-17	7,566
Feb-17	7,640
Mar-17	7,692
Apr-17	7,722
May-17	7,734
Jun-17	7,735
Jul-17	6,996
Aug-17	6,586
Sep-17	6,990
Oct-17	6,919
Nov-17	6,918
Dec-17	10,424

Table F-6 Hasil Peramalan Periode Kedepan dataset Sepingga

Bulan	Prediksi
Jan-17	1,318
Feb-17	1,531
Mar-17	1,460

Bulan	Prediksi
Apr-17	1,263
May-17	1,084
Jun-17	977
Jul-17	928
Aug-17	912
Sep-17	908
Oct-17	907
Nov-17	907
Dec-17	907